



Facultad de Ciencias Económicas y Empresariales

SilverHub: Proyecto de Análisis de Datos para la Evaluación del Sector “*Senior Living*” en España

Clave: 202001560

Estudiante: Ignacio García Ramos

Director: Dr. Prof. Rafael Vara García

MADRID | abril 2025

Resumen

Este trabajo analiza la viabilidad económica, social y estratégica del modelo SilverHub, un complejo residencial prefabricado dirigido a personas mayores autónomas en España. Tras aplicar análisis PESTEL y las Cinco Fuerzas de Porter, se identifican oportunidades clave en el mercado del “*senior living*”. Se emplean técnicas estadísticas avanzadas (PCA y “*clustering*”) para seleccionar estratégicamente las provincias más adecuadas, siendo Madrid y Barcelona las óptimas para los complejos piloto. Mediante simulaciones Monte Carlo, se proyectan ingresos, costes y beneficios durante 20 años bajo tres escenarios. Los resultados confirman la viabilidad del modelo, destacando la importancia de mantener una ocupación mínima del 60 % y fomentar la adopción del plan premium. Finalmente, se establecen recomendaciones estratégicas para asegurar la sostenibilidad del proyecto.

Palabras clave: “*Senior living*”, “*Silver Economy*”, Vivienda prefabricada, “Clustering”, Envejecimiento activo, Monte Carlo.

Abstract

This paper analyzes the economic, social, and strategic viability of the SilverHub model, a prefabricated residential complex aimed at independent older adults in Spain. Following a PESTEL analysis and Porter’s Five Forces, key opportunities in the senior living market are identified. Advanced statistical techniques (PCA and clustering) are applied to strategically select the most suitable provinces, with Madrid and Barcelona emerging as optimal locations for the pilot complexes. Through Monte Carlo simulations, income, costs, and profits are projected over a 20-year horizon under three market scenarios. The results confirm the model’s viability, highlighting the importance of maintaining a minimum occupancy rate of 60% and promoting adoption of the premium plan. Finally, strategic recommendations are proposed to ensure the long-term sustainability of the project.

Keywords: Senior living, Silver Economy, Prefabricated housing, Clustering, Active ageing, Monte Carlo.

Contenido

Índice de Figuras	4
1. Introducción.....	6
1.1 Interés en la cuestión	6
1.1.1 Problema.....	6
1.1.2 Relevancia en la actualidad	7
1.1.3 Propósito.....	8
1.2 Objetivo del trabajo	8
1.3 Metodología	9
2. Propuesta de valor.....	10
2.1 Explicación de la idea	10
2.1.1 Modelo de negocio.....	10
2.1.2 Distribución del complejo	11
2.2 Visión, misión y valores	13
3. Análisis del entorno	14
3.1 Macroentorno – PESTEL	14
3.1.1 Económicos.....	14
3.1.2 Factores sociales	19
3.1.3 Factores políticos y legales.....	23
3.1.4 Medioambientales	24
3.2 Microentorno – 5 Fuerzas de Porter	25
3.2.1 Rivalidad existente entre competidores	25
3.2.2 Amenaza de nuevos competidores.....	26
3.2.3 Poder de negociación de los proveedores	27
3.2.4 Amenaza de servicios sustitutivos	27
4. Posicionamiento estratégico	28
4.1 Público objetivo	28
4.2 Análisis de datos para la selección de la ubicación	29
4.2.1 Definición de los elementos del estudio	29
4.2.2 Análisis exploratorio y reducción de la dimensionalidad (PCA)	30
4.2.3 Selección del número de “clusters”.....	33
4.2.4 “Clustering”	35
4.2.5 Evaluación de perfiles y selección final de la ubicación	38
5. Estructura financiera y proyecciones.....	40
5.1 Fuentes de ingresos	40
5.2 Costes esperados	44
5.3 Resultados del proyecto	47
6. Consideraciones finales.....	50

Anexos	52
Anexo I. Código R para el análisis exploratorio y reducción de la dimensionalidad (PCA)	52
Anexo II. Código R para determinar el número de “clusters”	53
Anexo III. Código R para el “clustering” jerárquico	54
Anexo IV. Código R para el “clustering” con k-means	55
Anexo V. Código R para la evaluación de perfiles y selección final de la ubicación	55
Anexo VI. Código Python para la simulación de estructura de ingresos	57
Anexo VII. Código Python para la simulación de estructura de costes	62
Anexo VIII. Código Python para la simulación del beneficio	67
Anexo IX. Estadísticas y evolución de la simulación de la estructura financiera	70
Anexo X. Declaración de uso de IA	76
Bibliografía	77

Índice de Figuras

Figura 1: Plano técnico de cada casa prefabricada

Figura 2. Pensión de jubilación media por provincias a finales de 2024

Figura 3. Precio medio sin IVA en euros de las residencias de ancianos por provincias en 2024 y población mayor de 65 años por provincias en 2024

Figura 4. Precio medio del suelo urbano por Comunidad Autónoma para 2024

Figura 5. Precio medio del suelo urbano por provincia para el año 2024

Figura 6. Gráfico comparativo de la esperanza de vida de España y de la UE

Figura 7. Pirámides de población para España – 1998 vs 2022

Figura 8. Proyección del índice de envejecimiento

Figura 9. Proyección de la evolución del porcentaje de población mayor de 64 años en España

Figura 10. Matriz de correlación

Figura 11. Varianza Explicada y Acumulada por Componente Principal

Figura 12. “Biplot” del PCA

Figura 13. Método del Codo

Figura 14. Método de la silueta

Figura 15. Dendograma con distancia Euclídea y enlace de Ward

Figura 16. Visualización del “*clustering*” jerárquico con 3 grupos en 2 dimensiones

Figura 17. Visualización del “*clustering*” con “*k-means*” con $k=4$ en 2 dimensiones

Figura 18. Gráfico de la silueta del “*clustering*” jerárquico

Figura 19. Gráfico de la silueta de “*clustering*” con “*k-means*”

Figura 20. “*Profile plot of centroids*”

Figura 21. Tabla de asignación de las provincias a cada “*cluster*”

Figura 22. Simulación de ingresos interanuales por escenario

Figura 23. Simulación de ingresos acumulados por escenario

Figura 24. Simulación de costes interanuales por escenario

Figura 25. Simulación de costes acumulados por escenario

Figura 26. Simulación de beneficios interanuales

Figura 27. Simulación de beneficios acumulados



SilverHub

“Vivir con propósito, envejecer con libertad”

1. Introducción

1.1 Interés en la cuestión

1.1.1 Problema

El acelerado envejecimiento poblacional representa un desafío considerable para España, con un aumento progresivo de la población mayor que impulsa una mayor demanda de soluciones residenciales adaptadas. Sin embargo, la oferta actual en el sector del *“senior living”* está lejos de satisfacer esta demanda creciente, generando un desequilibrio significativo en el mercado. Actualmente, España cuenta con aproximadamente 380.000 camas adaptadas para personas mayores, lo que supone 3,1 camas por cada 100 personas senior, muy por debajo del estándar recomendado por la OMS de cinco camas por cada 100 seniors (Lospitao, 2022). Según Alonso (2022), citando a Nuria Béjar, el 80% de los mayores de 65 años está en buen estado de salud, lo que indica un mercado potencial considerable para servicios y viviendas adaptadas a personas mayores con cierto nivel de autonomía. Esta estadística subraya la creciente necesidad de viviendas que soporten un estilo de vida activo y autónomo entre la población mayor. Además, la soledad y el aislamiento social son reconocidos por la Organización Mundial de la Salud (OMS) como factores de riesgo clave para el desarrollo de afecciones de salud mental en etapas avanzadas de la vida. Según la OMS (2023), estas condiciones pueden aumentar el riesgo de depresión, ansiedad y deterioro cognitivo, además de tener un impacto negativo sobre la salud física, como un mayor riesgo de enfermedades cardiovasculares y mortalidad prematura. Por ello, resulta fundamental que las personas mayores no se sientan solas y tengan la oportunidad de vivir en comunidad, rodeadas de vínculos sociales significativos

que favorezcan su bienestar emocional y su autonomía.

1.1.2 Relevancia en la actualidad

Este problema es particularmente relevante hoy debido al rápido envejecimiento de la población española, donde la esperanza de vida alcanzó los 84 años en 2023, superior a la media europea, y aproximadamente un 20% de la población tiene ya más de 65 años (Instituto Geográfico Nacional, s.f.). Esta tendencia seguirá aumentando, proyectándose que para 2039 más del 26% de la población española será mayor de 65 años, alcanzando cerca del 30% hacia 2050 (INE, s.f.-g). Asimismo, se estima que la población mayor de 80 años aumentará un 47,5% en los próximos 15 años, pasando de 3 millones en 2024 a más de 4,34 millones en 2039. Incluso, el número de centenarios se espera que se triplique, pasando de 17.000 en 2024 a más de 49.000 en 2039 (Sosa Troya, 2024).

Este notable envejecimiento de la población española se refleja también en el índice de envejecimiento, que mide la proporción entre personas mayores de 64 años frente a menores de 16 años. En 2023 este índice alcanzó un récord histórico de 137 mayores por cada 100 menores, y se espera que siga aumentando considerablemente hasta alcanzar un pico del 253% en las próximas décadas (Fundación Adecco, s.f.).

Paralelamente, los mayores presentan cada vez más preferencia por residir en viviendas que promuevan su autonomía e independencia, alejándose del modelo tradicional de residencias geriátricas, que habitualmente se asocia a situaciones de dependencia severa y al final de la vida. De hecho, tan solo entre el 3% y el 4% de los mayores españoles vivían en residencias en 2022, y la gran mayoría optaba por continuar viviendo en sus hogares, siempre que estos fueran adaptados a sus condiciones de salud y movilidad (Alonso, 2022).

Además, las familias están mostrando una percepción cada vez más favorable respecto a invertir en soluciones residenciales alternativas para personas mayores. En 2023, el 25% de las familias españolas afirmó estar dispuesto a pagar más de 2.000 euros mensuales por una plaza residencial para sus familiares mayores, lo que refleja un cambio significativo frente a años anteriores. Esta tendencia se fortalece por el hecho de que el 92% de los hogares con personas mayores de 65 años posee una vivienda en propiedad, representando una fuente de capital que puede ser monetizada para cubrir los costes

residenciales (Inforesidencias, 2023; Puga, 2023).

Finalmente, es importante mencionar que la oferta actual de viviendas adaptadas para mayores autónomos es insuficiente para satisfacer la creciente demanda derivada de estas tendencias demográficas y sociales, evidenciado por lo comentado previamente sobre el número de camas, entre otras cosas. Esta escasez en la oferta resalta aún más la relevancia y urgencia de desarrollar soluciones innovadoras como SilverHub, capaces de satisfacer adecuadamente las necesidades emergentes del mercado residencial senior.

1.1.3 Propósito

Ante este contexto, el propósito principal de este trabajo es realizar un análisis exhaustivo y profundo del sector del “*senior living*” en España, explorando tanto el entorno macroeconómico como el competitivo, para identificar oportunidades estratégicas clave. Con base en este análisis, se propone desarrollar un modelo residencial innovador, sostenible y económicamente viable, específicamente orientado a satisfacer las necesidades emergentes de la población mayor autónoma. En concreto, se pretende diseñar una alternativa residencial atractiva que integre viviendas adaptadas con una amplia gama de servicios complementarios que faciliten la vida diaria, promuevan la independencia y fortalezcan las relaciones sociales de sus residentes. Este modelo residencial aspira no solo a mejorar sustancialmente la calidad de vida de las personas mayores, sino también a ofrecer una solución efectiva frente a la creciente problemática del aislamiento social y emocional en esta población. En definitiva, el propósito es contribuir al bienestar integral de los mayores, fomentando un envejecimiento activo, autónomo y socialmente conectado, en línea con las recomendaciones internacionales y las tendencias sociodemográficas identificadas en este estudio.

1.2 Objetivo del trabajo

El objetivo principal de este trabajo es evaluar la viabilidad económica, social y estratégica del modelo SilverHub, un complejo residencial de edificación prefabricada orientado a personas mayores autónomas. Para alcanzar este objetivo general, se establecen los siguientes objetivos específicos:

- Realizar un análisis exhaustivo del entorno macroeconómico mediante el modelo PESTEL, para identificar oportunidades y amenazas clave en el mercado.

- Analizar la estructura competitiva del sector “*senior living*” utilizando el modelo de las Cinco Fuerzas de Porter, con el fin de evaluar la rivalidad competitiva y el atractivo del mercado.
- Aplicar técnicas de análisis de datos avanzadas como análisis de componentes principales (PCA) y “*clustering*”, para segmentar territorialmente y determinar las ubicaciones óptimas del proyecto SilverHub en España.
- Evaluar mediante simulaciones financieras (Monte Carlo) la rentabilidad y viabilidad económica del modelo SilverHub bajo diferentes escenarios del mercado.
- Definir recomendaciones estratégicas claras que aseguren la sostenibilidad y el éxito a largo plazo del proyecto SilverHub.

1.3 Metodología

Para lograr los objetivos específicos planteados, se ha implementado una metodología mixta que combina enfoques cualitativos y cuantitativos, garantizando así un análisis integral y fundamentado del modelo SilverHub.

En primer lugar, se ha llevado a cabo una exhaustiva revisión de literatura especializada y un profundo análisis del entorno macroeconómico y competitivo. La investigación del mercado se ha sustentado en datos reales y fiables procedentes de fuentes oficiales y reconocidas internacionalmente, tales como el Instituto Nacional de Estadística (INE), la Organización de Naciones Unidas (ONU), la Organización Mundial de la Salud (OMS), y otros organismos especializados como la Fundación Adecco o el Instituto Geográfico Nacional. Esto ha permitido obtener una imagen completa y realista de la situación actual y futura del mercado residencial para personas mayores en España, incluyendo tendencias demográficas, capacidad de pago, y necesidades emergentes.

En segundo lugar, para realizar el análisis cuantitativo del territorio y determinar la ubicación óptima del complejo residencial SilverHub, se ha empleado RStudio como herramienta de análisis y visualización de datos. La elección de RStudio obedece a su versatilidad, facilidad de implementación, robustez estadística y amplia disponibilidad de librerías especializadas para análisis estadísticos y visualización avanzada de resultados.

Dentro del análisis territorial, se ha seleccionado el Análisis de Componentes Principales

(PCA, por sus siglas en inglés) como técnica estadística para reducir dimensionalidad y eliminar altas correlaciones entre variables. Esta reducción facilita la identificación de los patrones subyacentes más relevantes en las características socioeconómicas de las provincias españolas. De este modo, el PCA permite sintetizar la información esencial del mercado potencial de forma objetiva y visualizable. Posteriormente, sobre los componentes obtenidos se han aplicado técnicas de “*clustering*”, con el fin de segmentar y agrupar territorios con perfiles homogéneos, permitiendo así una identificación clara de las ubicaciones más favorables para la implementación inicial del modelo SilverHub.

Finalmente, para evaluar la rentabilidad y viabilidad financiera del proyecto, se ha seleccionado el modelo de simulación financiera Monte Carlo. La justificación del uso de esta técnica radica en su capacidad para incorporar incertidumbre y variabilidad mediante múltiples iteraciones de potenciales escenarios. El modelo Monte Carlo permite así estimar de manera robusta y confiable la rentabilidad esperada, los riesgos potenciales y la sensibilidad del proyecto frente a diversos factores económicos y operativos, aportando una visión más realista y prudente de las expectativas de retorno y sostenibilidad económica del modelo SilverHub.

Con la combinación de estos enfoques y herramientas metodológicas avanzadas, este trabajo asegura un análisis riguroso y detallado del modelo SilverHub desde todas sus perspectivas relevantes: económica, social, estratégica y territorial.

2. Propuesta de valor

2.1 Explicación de la idea

2.1.1 Modelo de negocio

El modelo de negocio de SilverHub se centra en la creación de un complejo de viviendas prefabricadas, diseñado especialmente para personas mayores que aún conservan un cierto grado de independencia. La propuesta es ofrecer un entorno en el que los residentes no se sientan confinados ni “aparcados” en un entorno tradicional de residencia para mayores, sino que puedan disfrutar de una vida propia, manteniendo su autonomía y fomentando la socialización.

En este complejo se integran viviendas individuales, diseñadas para proporcionar privacidad y comodidad, junto con un conjunto de servicios comunitarios y

especializados que incluyen, entre otros, comedor y cocina central, zonas de ejercicio, centro de fisioterapia y rehabilitación, sala social para actividades recreativas y espacios para talleres y tecnología. Estos servicios, que se ofrecen de forma compartida, tienen como objetivo principal crear un ambiente de interacción y apoyo mutuo, combatiendo así el aislamiento social que suele afectar a las personas mayores.

El acceso a SilverHub se realiza a través de un sistema de alquiler mensual, donde cada residente abona una cuota fija que cubre tanto la utilización de la vivienda como el acceso a todos los servicios e instalaciones. Esta modalidad de suscripción mensual genera ingresos recurrentes que permiten garantizar la sostenibilidad del proyecto a lo largo del tiempo, al mismo tiempo que se ofrecen soluciones flexibles y adaptadas a las necesidades cambiantes de los mayores.

2.1.2 Distribución del complejo

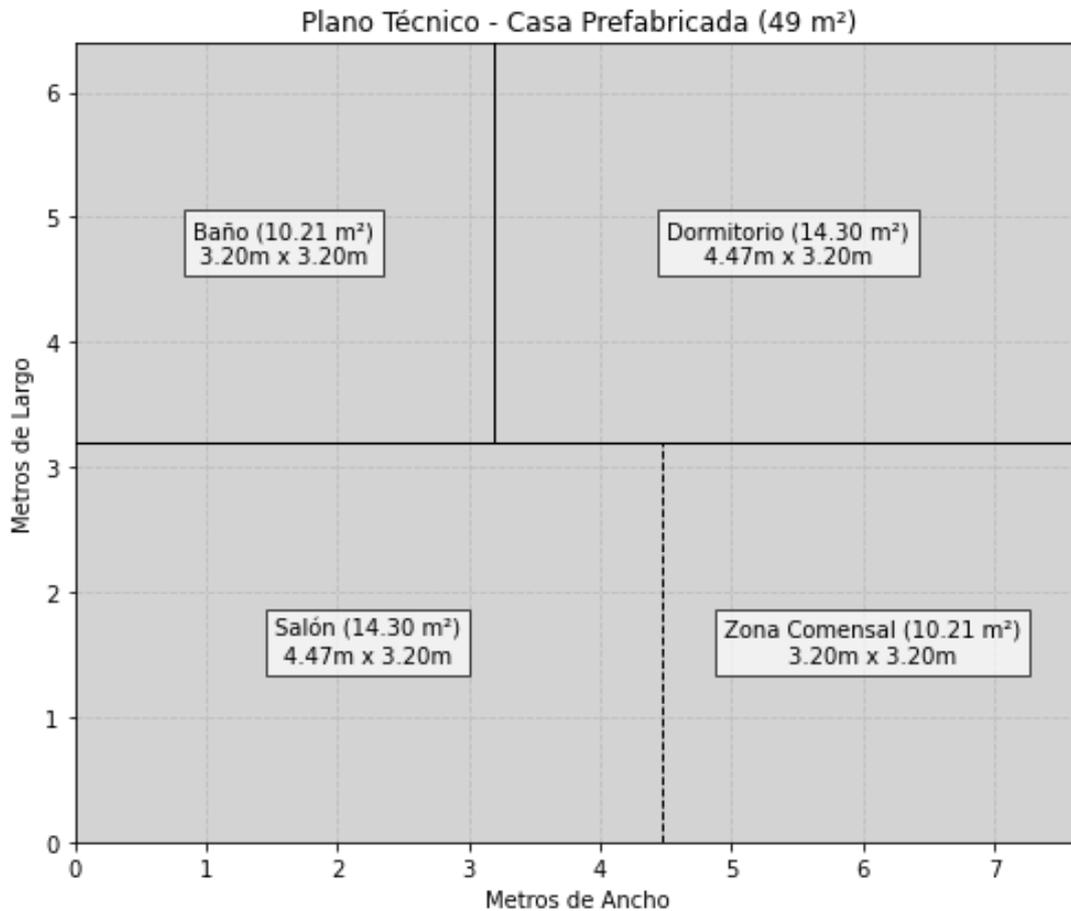
El complejo está compuesto por las casas prefabricadas donde residen los clientes y las áreas comunes a las que tienen acceso:

- Casa prefabricada: consta de 49 metros cuadrados diseñados específicamente para ofrecer un espacio funcional, cómodo y adaptado a las necesidades de cada residente. La Figura 1 muestra los planos de cómo se estructuraría cada unidad.
- Comedor comunitario y cocina central: El comedor comunitario es un espacio esencial dentro del complejo, diseñado para garantizar una alimentación equilibrada y fomentar la interacción social.
- Área de ejercicio y movilidad: el mantenimiento de la movilidad y la actividad física regular es fundamental para preservar la autonomía en la vejez, uno de los objetivos principales de SilverHub. A este espacio se le sumará una piscina cubierta para realizar actividades acuáticas.
- Centro de fisioterapia y rehabilitación: En línea con el objetivo de mantener la independencia de los residentes el mayor tiempo posible, SilverHub incorporará un centro de fisioterapia y rehabilitación como uno de los servicios clave dentro del complejo.
- Enfermería básica: El acceso inmediato a servicios de enfermería y atención médica básica es un aspecto esencial en comunidades diseñadas para personas mayores. Aunque SilverHub no es un centro sanitario, sí contará con una enfermería equipada

para la gestión de la salud diaria de los residentes, garantizando su bienestar sin necesidad de desplazamientos frecuentes a centros médicos. Además, facilitará la gestión de medicación, permitiendo que los residentes reciban sus tratamientos sin necesidad de acudir a farmacias. Otro aspecto clave será la coordinación con especialistas externos, permitiendo la derivación a médicos en caso de que algún residente requiera una atención más específica.

- Espacio de socialización y actividades recreativas: en línea con lo que establece Cattán et al. (2005) en su estudio, el aislamiento social es un factor de riesgo para el deterioro cognitivo y la depresión en la vejez. Es por ello por lo que, SilverHub, contará con un espacio de reunión y de actividades, diseñado para fomentar la interacción de los residentes y su actividad diaria. Así, se proporcionará un entorno donde puedan desarrollar actividades recreativas, culturales y de ocio.
- Servicio de apoyo y asistencia personalizada: si bien uno de los pilares fundamentales de SilverHub es que los residentes mantengan su independencia, pero siempre sin comprometer su seguridad y bienestar. Para garantizar la seguridad de los residentes, el complejo contará con un servicio de asistencia disponible las 24 horas, ofreciendo apoyo inmediato en caso de emergencia y garantizando una respuesta rápida ante cualquier imprevisto.

Figura 1: Plano técnico de cada casa prefabricada.



Nota. La línea discontinua muestra una separación ficticia, ya que no hay una separación física entre medias.

2.2 Visión, misión y valores

Visión: Ser el referente en España de envejecimiento activo, comunitario, autónomo y con propósito.

Misión: Ofrecer una alternativa de vivienda que se enmarca entre el hogar tradicional y las residencias, diseñada para personas mayores que desean vivir en comunidad, con autonomía y acceso a servicios personalizados que promueven el bienestar, la salud y la sociabilidad. SilverHub facilita un entorno seguro, estimulante y adaptado, que responde a las crecientes necesidades que se derivan del envejecimiento en España.

Valores:

1. Autonomía: promovemos la independencia de nuestros residentes respetando sus ritmos, decisiones y estilos de vida, garantizando siempre apoyo cuando lo

necesiten

2. Comunidad: fomentamos las relaciones entre residentes mediante espacios de convivencia para combatir la soledad y crear un sentido de pertenencia.
3. Bienestar: abordamos el envejecimiento desde una perspectiva holística, combinando la salud física, mental, emocional y social en todos nuestros servicios.
4. Tecnología: impulsamos la inclusión digital de las personas mayores mediante talleres, herramientas y entornos adaptados con el fin de reducir la brecha tecnológica generacional.
5. Adaptabilidad: diseñamos entornos accesibles, funcionales y flexibles que se adaptan a la evolución de las capacidades y preferencias de nuestros residentes.
6. Sostenibilidad social y medioambiental: creamos impacto positivo en las comunidades y en el entorno, apostando por modelos de convivencia y de construcción sostenibles y responsables.

3. Análisis del entorno

3.1 Macroentorno – PESTEL

3.1.1 Económicos

- Demanda y Oferta en el Mercado de Vivienda Senior

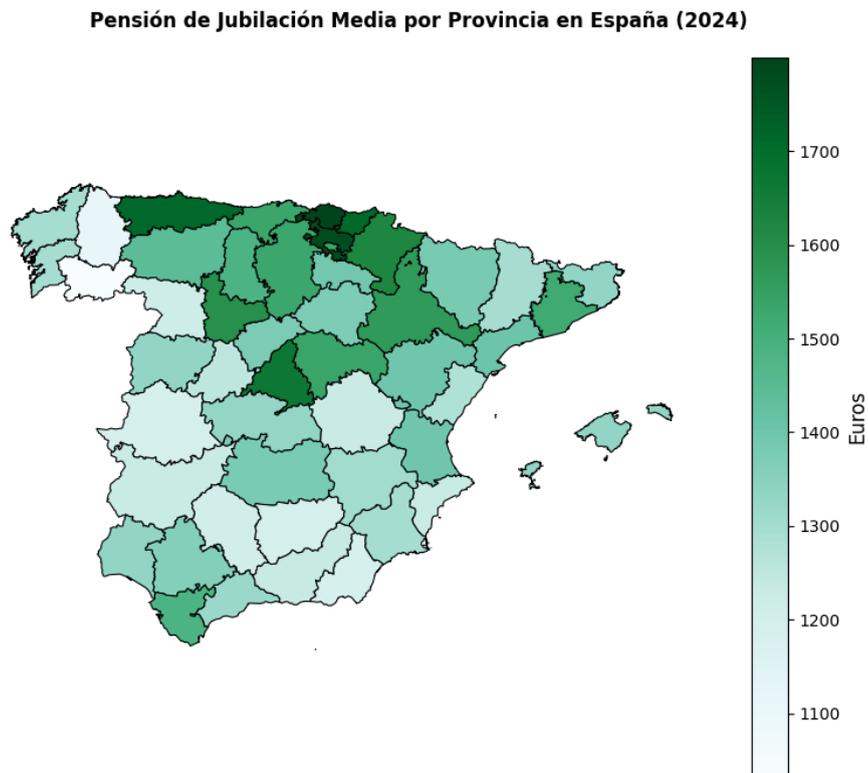
Existe una notable discrepancia en España entre la demanda creciente por servicios y viviendas adaptadas para personas mayores, que buscan mantener un cierto nivel de autonomía, y la oferta actual disponible. Actualmente, el país cuenta con solo 380.000 camas de “*senior living*”, lo que representa aproximadamente 3,1 camas por cada 100 personas mayores, cifra que se queda corta frente a las cinco camas por cada 100 personas mayores recomendadas por la OMS. Para cumplir con ese objetivo, se tendrían que invertir 1.445 millones de euros al año hasta 2030. Este desequilibrio subraya una oportunidad considerable para los desarrolladores y proveedores de vivienda para mayores, incentivando la expansión y mejora de la infraestructura para satisfacer las necesidades del mercado y las recomendaciones de organismos internacionales (Lospitao, 2022).

- Capacidad de Pago de las Personas Mayores

Otro factor que tampoco puede pasarse por alto en este análisis es la capacidad de pago de las personas mayores, ya que determina en qué medida podrán afrontar los costes de una plaza residencial. Esta capacidad viene dada, principalmente, por el nivel medio de las pensiones de jubilación. A finales de 2024, la pensión de jubilación media en España fue de 1.445,75€ mensuales (Ministerio de Inclusión, Seguridad Social y Migraciones, 2024). Esto significa que, en términos generales, el precio medio de una residencia, 1.816,17€/mes sin IVA, supera notablemente los ingresos mensuales por pensión, obligando a muchos mayores a tener que complementar el pago con ahorros, patrimonio personal o apoyo familiar (Geriatricarea, 2024). La Figura 2 muestra claramente la variabilidad geográfica en la pensión de jubilación media, donde se puede apreciar que, mientras que en provincias del norte como Álava, Vizcaya o Asturias las pensiones superan los 1.600€ mensuales, en gran parte de Andalucía, Extremadura y Galicia se sitúan por debajo de los 1.300€, lo que evidencia diferencias significativas en el poder adquisitivo de los potenciales residentes. Por otro lado, las dos grandes ciudades, Madrid y Barcelona, también presentan pensiones superiores a la media nacional, con 1.665,36 € y 1.518,70 € respectivamente (Ministerio de Inclusión, Seguridad Social y Migraciones, 2024), lo que refuerza su posición como zonas clave para captar demanda en soluciones residenciales para mayores.

A pesar de la brecha entre los precios de las residencias y las pensiones, la percepción de las familias hacia el gasto en residencias ha mejorado. Un 25% de las familias estaban dispuestas a pagar más de 2.000€ al mes por una residencia en 2023, un aumento respecto al año anterior del 9%. Además, algo que influye en esa diferencia no afecte a la percepción del familiar es que, en España, la gran mayoría de personas mayores de 65 años poseen una vivienda. Un 76% de la población posee una vivienda propia. Además, el 92% de los hogares que tienen una persona mayor de 65 años posee una casa. Esto implica que muchos mayores cuentan con un patrimonio inmobiliario que pueden monetizar (venta o renta de su casa) para permitirse una plaza en un “*senior living*” (Inforesidencias, 2023; Puga, 2023).

Figura 2. Pensión de jubilación media por provincias a finales de 2024



Fuente: elaboración propia con datos del Ministerio de Inclusión, Seguridad Social y Migraciones (2024).

- Impacto Económico del Envejecimiento Poblacional

España se enfrenta a un fuerte envejecimiento poblacional, con un incremento sostenido de la población senior y una esperanza de vida en continuo ascenso. Este contexto impulsa la expansión de la “*Silver Economy*” y la necesidad de nuevas soluciones habitacionales. Por lo tanto, SilverHub está avalado por estas tendencias demográficas, ofreciendo un modelo innovador que promueve la autonomía, el bienestar y la integración social de las personas mayores.

La “*Silver Economy*” ha sido definida por la Universidad Pontificia de Comillas (2021) como la economía centrada en las personas mayores, en respuesta a la creciente tendencia de envejecimiento poblacional.

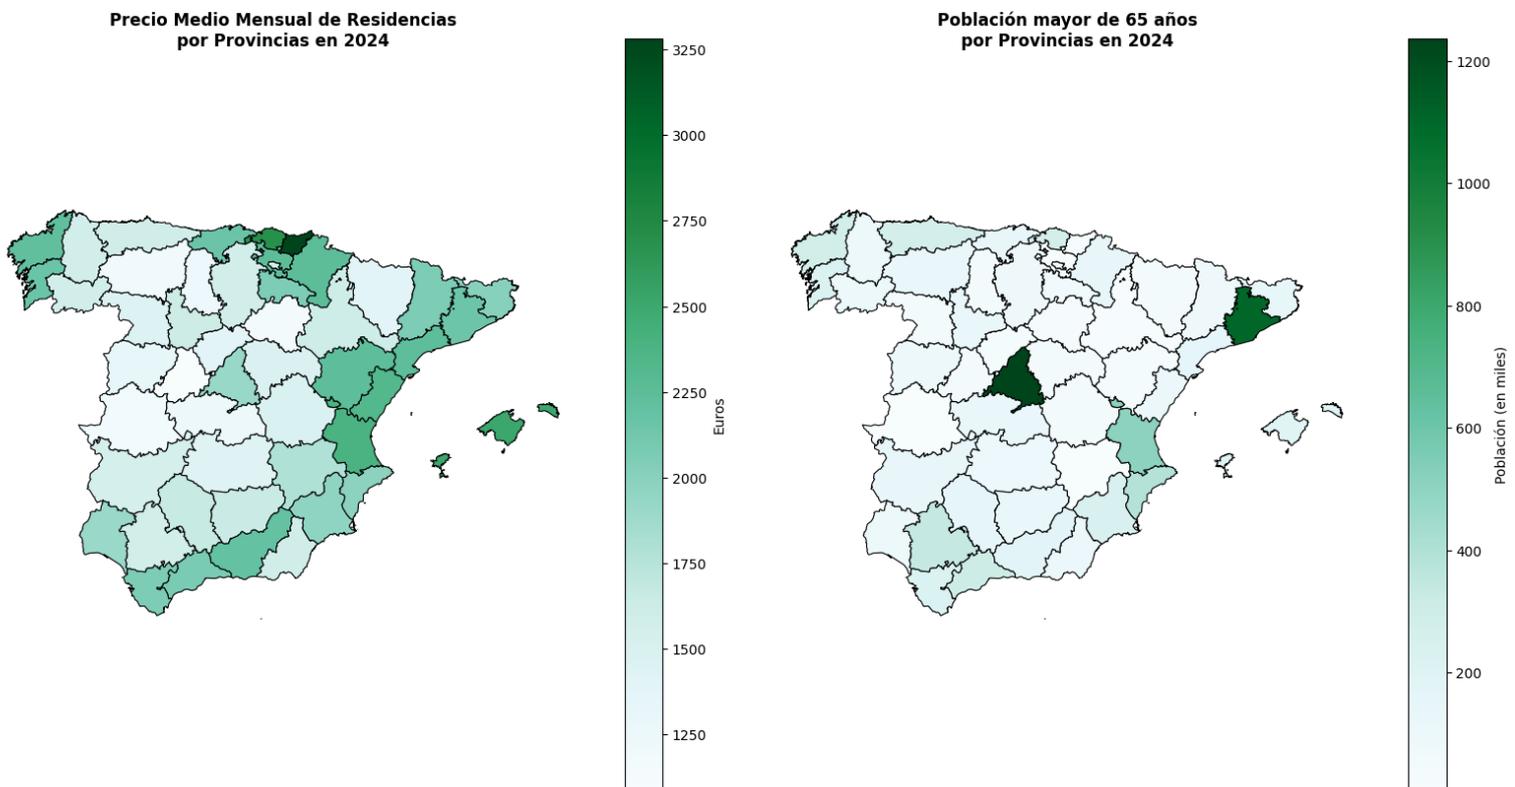
- Precio Medio de Residencias de Ancianos

En España, las residencias de ancianos tuvieron un coste medio sin IVA en 2024 de alrededor de 1.816,17€ al mes (Geriatricarea¹, 2024). Esto se trata de una media nacional,

¹ Geriatricarea es una revista digital especializada en el sector sociosanitario, que ha difundido un estudio elaborado por MiResi, una plataforma líder en la comparación de residencias en España.

pero existen grandes variaciones dependiendo de la provincia donde estén ubicadas. Esta variación se puede ver en la Figura 3 donde se muestra el precio medio sin incluir el IVA de las residencias de mayores en España para el año 2024. El rango de precios varió significativamente entre provincias, con Ávila siendo la más económica con un coste medio de 1.087,65€, mientras que Gipuzkoa se posicionó como la más cara, alcanzando los 3.281,82€, lo que representa una diferencia de más del 200% entre ambas.

Figura 3. Precio medio sin IVA en euros de las residencias de ancianos por provincias en 2024 y población mayor de 65 años por provincias en 2024



Fuente: elaboración propia con los datos de Geriatricarea (2024), revista digital del sector sociosanitario.

Las regiones del norte, como el País Vasco, tienden a tener los precios más altos, mientras que las áreas interiores y del oeste ofrecen precios más asequibles. Sin embargo, las áreas con alta concentración de personas mayores, como Madrid y Barcelona, aunque no tienen los precios más elevados, tienen una demanda potencial significativa debido a su alta población envejecida (Geriatricarea, 2024).

- Variabilidad del Coste del Suelo Urbano

Además de los factores que afectan directamente en los clientes como puede ser el precio o las pensiones de jubilación, es importante analizar el coste del suelo urbano en España,

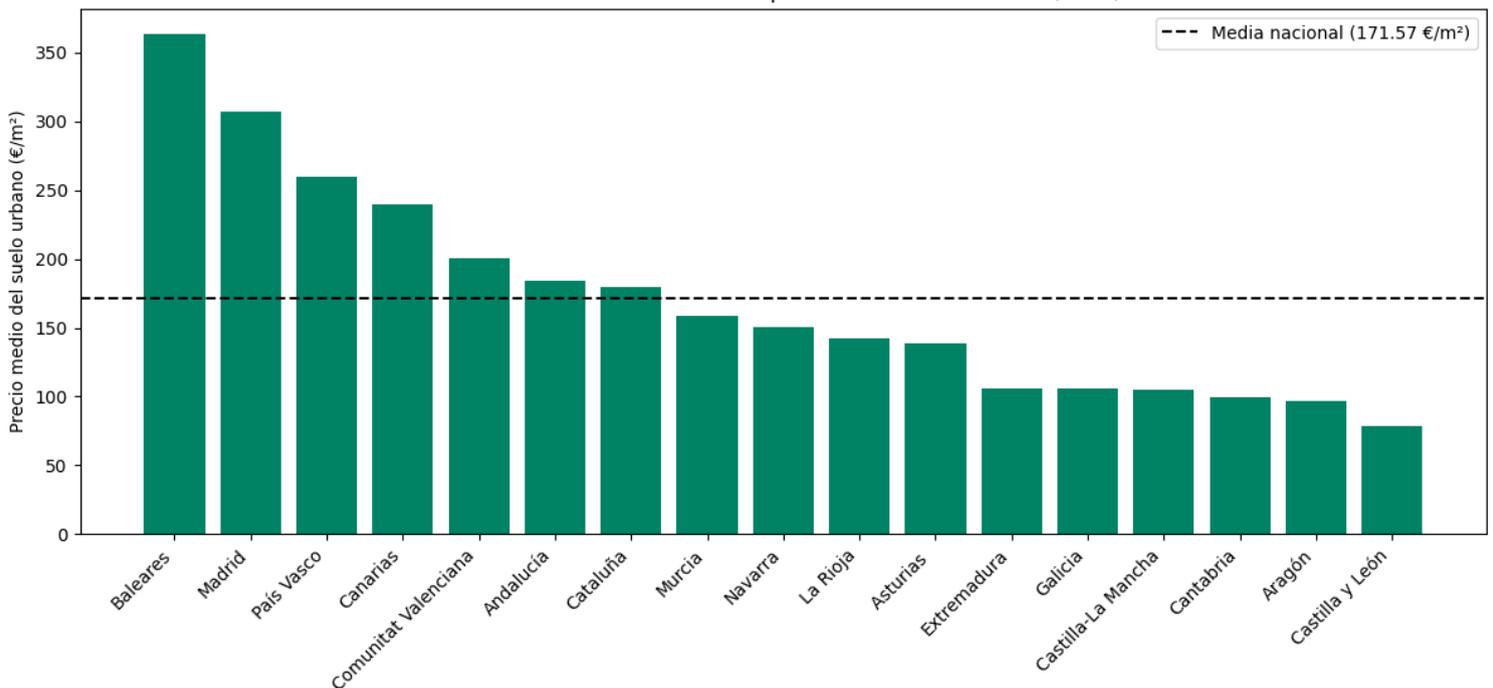
ya que para SilverHub será necesario adquirir terrenos para su desarrollo. Por ello, es necesario conocer las diferencias geográficas en el precio del metro cuadrado de suelo urbano es clave para evaluar la viabilidad financiera del proyecto según su localización.

La Figura 4 muestra el precio medio del metro cuadrado de suelo urbano por Comunidad Autónoma en 2024. Se observa que Baleares lidera el ranking con un valor superior a los 360 €/m², seguida de Madrid (más de 306 €/m²) y País Vasco. En el otro extremo, regiones como Castilla y León, Aragón y Cantabria presentan valores muy por debajo de la media nacional (171,57 €/m²), situándose por debajo de los 100 €/m². Este contraste territorial refleja un escenario desigual que condiciona la inversión inicial en función de la localización.

La Figura 5 permite un análisis más detallado a nivel provincial, mostrando cómo algunas provincias dentro de comunidades con precios medios moderados tienen zonas con costes del suelo significativamente más altos, por ejemplo, Málaga tiene un precio muy superior al resto de las provincias de Andalucía. Por el contrario, provincias del interior como Cuenca, Teruel o Zamora muestran valores más reducidos, lo que podría abrir oportunidades de desarrollo en zonas menos saturadas, siempre que exista demanda potencial.

Figura 4. Precio medio del suelo urbano por Comunidad Autónoma para 2024

Precio Medio del Suelo Urbano por Comunidad Autónoma (2024)

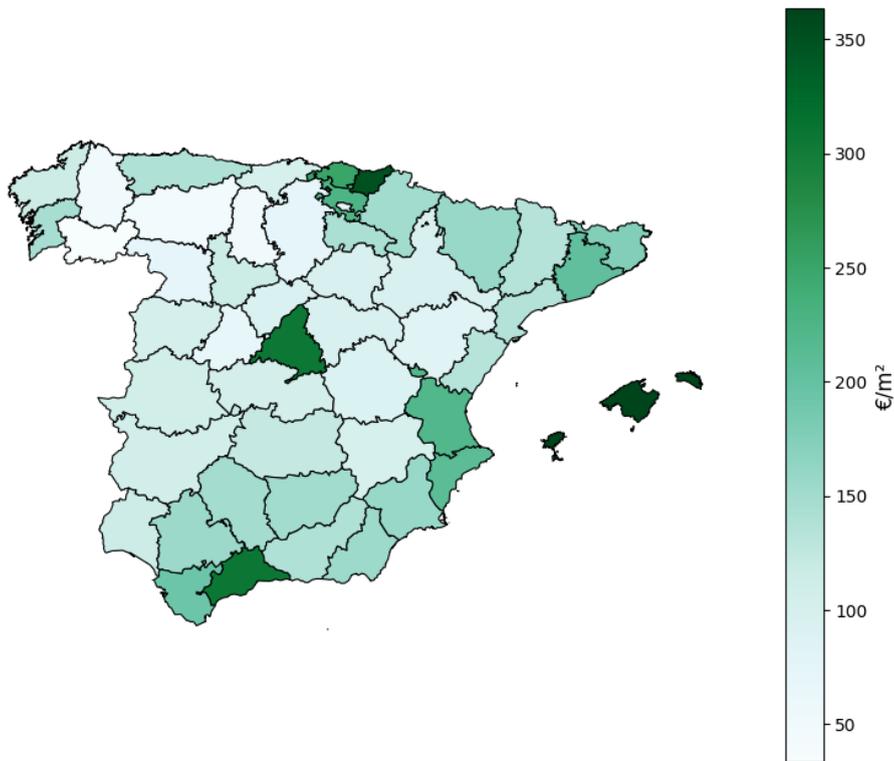


Fuente: elaboración propia con datos del Ministerio de Transportes y Movilidad Sostenible (s.f.). Los

datos venían distribuidos por trimestres por lo que se ha cogido la media de los cuatro trimestres para hacer el gráfico con el precio medio por metro cuadrado del año 2024.

Figura 5. Precio medio del suelo urbano por provincia para el año 2024

Precio Medio del Suelo Urbano por Provincia (2024)



Fuente: Gráfico de elaboración propia con datos del Ministerio de Transportes y Movilidad Sostenible (s.f.). Los datos venían distribuidos por trimestres por lo que se ha cogido la media de los cuatro trimestres para hacer el gráfico con el precio medio por metro cuadrado del año 2024.

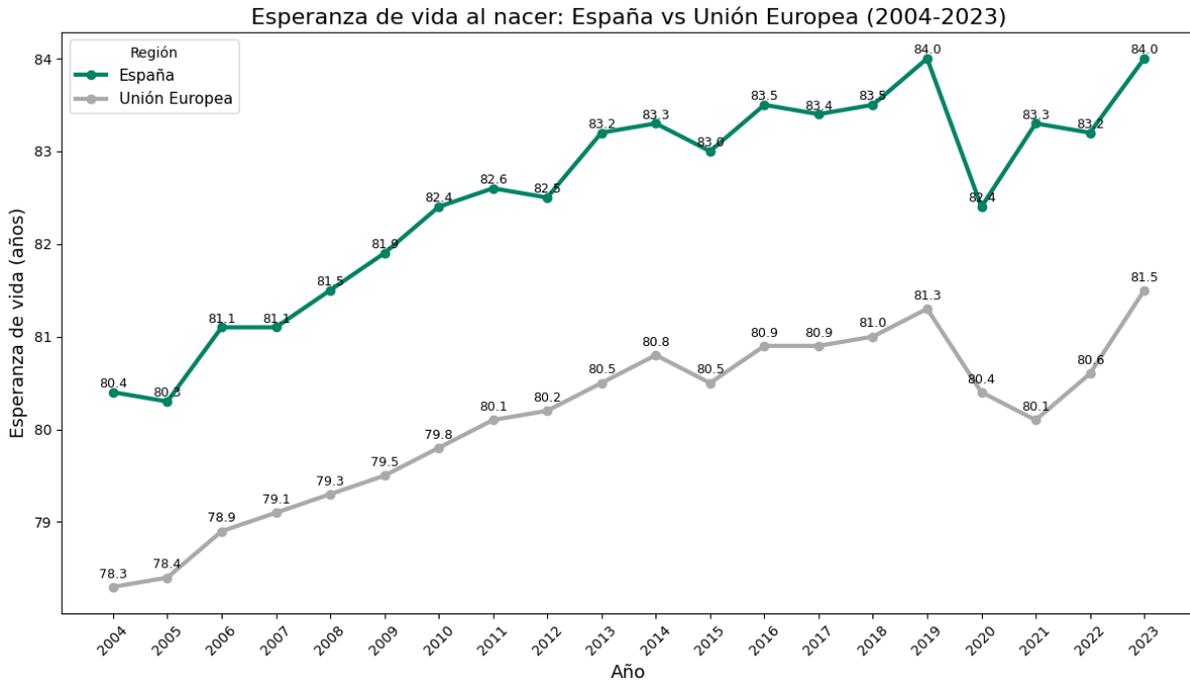
3.1.2 Factores sociales

- Esperanza de Vida y Envejecimiento Poblacional

España se encuentra entre los países más longevos del mundo, con una esperanza de vida de las más altas. En 2023, la esperanza de vida al nacer alcanzó los 84 años y, en la Figura 6, se puede ver una tendencia positiva en la esperanza de vida, que va aumentando con los años. Además, también se puede observar que la esperanza de vida en España es superior a la de la Unión Europea. Este aumento de la longevidad ha impulsado el crecimiento del segmento de mayores. En 2022 alrededor del 20% de la población española tenía 65 años o más (Instituto Geográfico Nacional, s.f.). En la Figura 7 se puede ver que la pirámide poblacional de España ha evolucionado de forma notable, en 1998 la mayoría de los datos se concentraban entre los 15 y los 40 años, mientras que, en 2022, se concentran entre los 40 y 60 años. Esto refleja el marcado envejecimiento demográfico

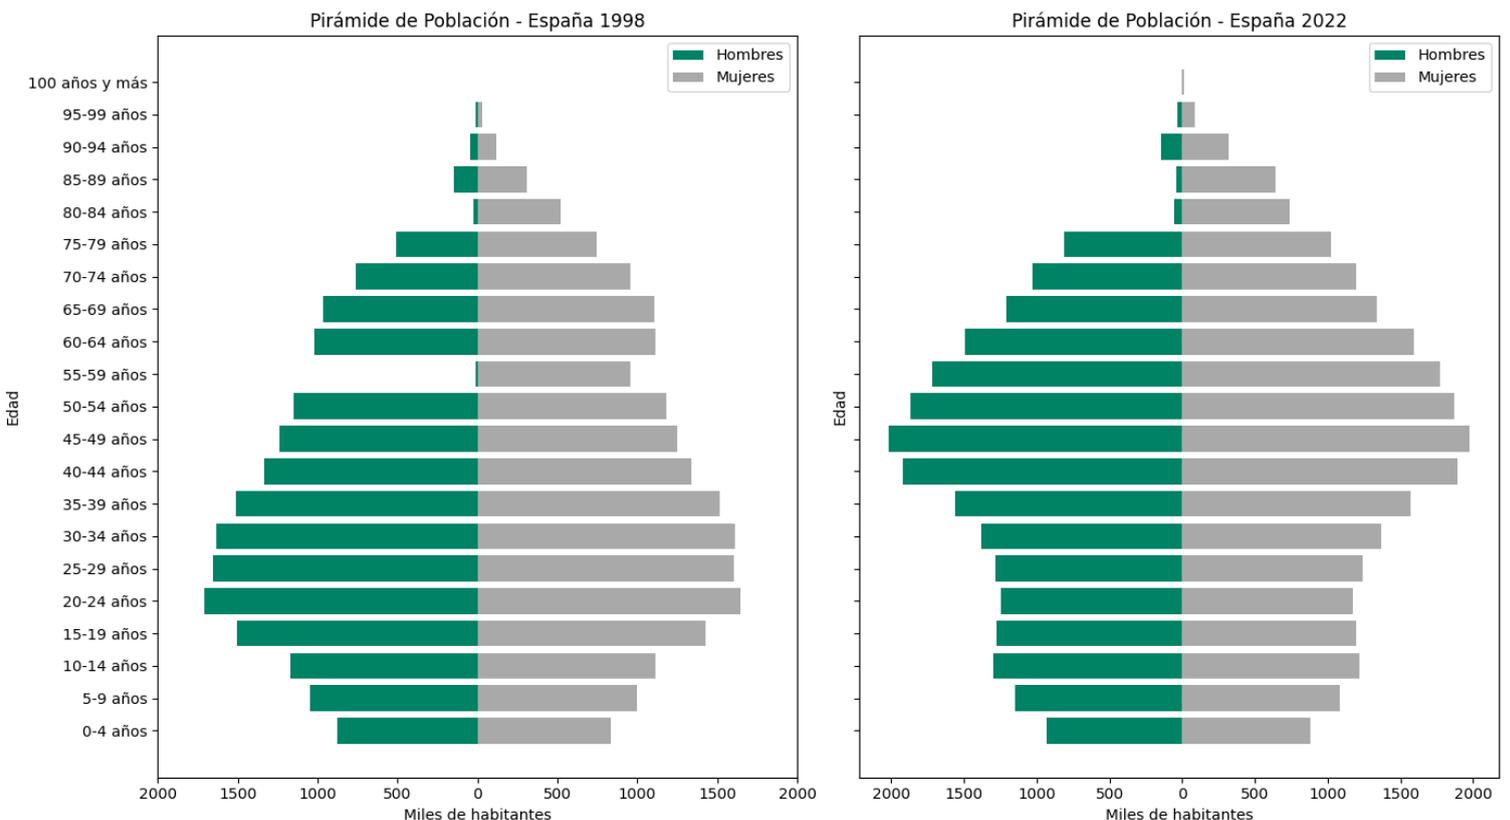
por el que está atravesando el país. Además, podemos esperar que la parte de mayor edad se haga cada vez más ancha, mientras que la parte inferior tienda a hacerse más estrecha.

Figura 6. Gráfico comparativo de la esperanza de vida de España y de la UE



Fuente: gráfico de elaboración propia con los datos del Eurostat (s.f.)

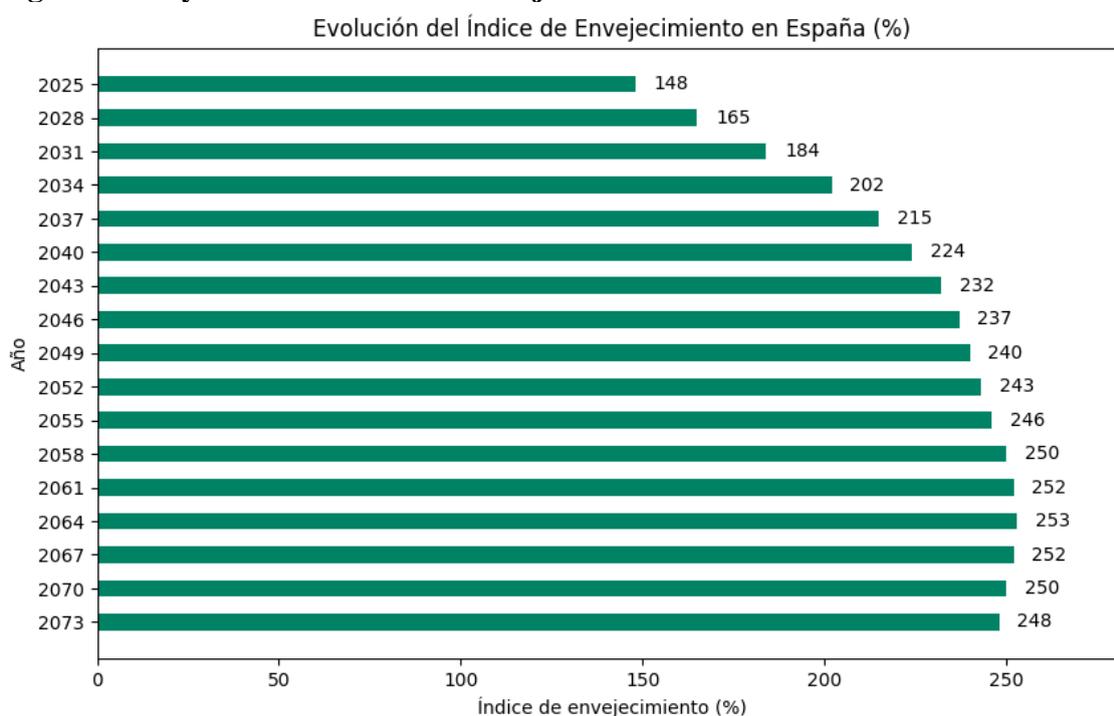
Figura 7. Pirámides de población para España – 1998 vs 2022



Fuente: elaboración propia con los datos del INE (s.f.-f).

Como consecuencia del aumento en la esperanza de vida y el envejecimiento poblacional, el índice de envejecimiento en España alcanzó un récord de 137 personas mayores de 64 años por cada 100 menores de 16 en 2023, mientras que en 1999 había mayor población menor de 16 años con un índice del 99.9% (Fundación Adecco, s.f.). En la Figura 8, se puede observar que se espera que el índice de envejecimiento tenga una tendencia ascendente alcanzando un pico del 253%, lo que significaría que habría 253 personas mayores de 64 años por cada 100 menores 16.

Figura 8. Proyección del índice de envejecimiento



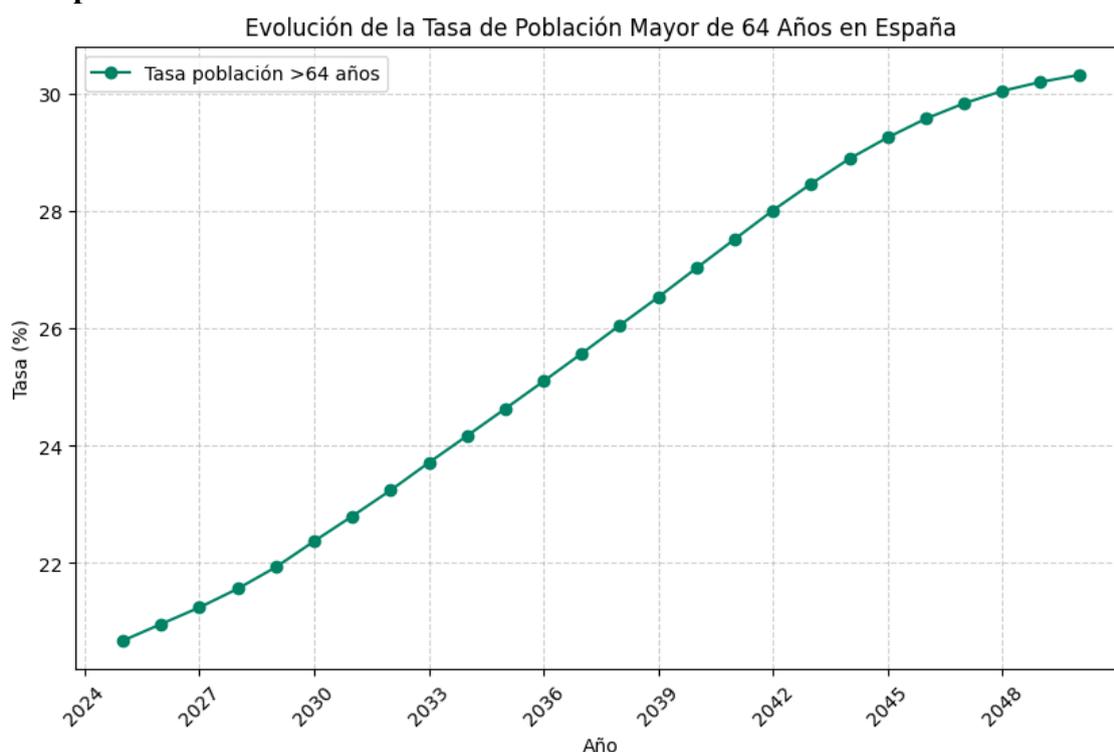
Fuente: Elaboración propia con datos del INE (s.f.-b). Es un indicador demográfico que mide el número de personas mayores (normalmente de 64 años o más) por cada 100 menores de 16 años en una población determinada. Si el índice es mayor a 100, significa que hay más personas mayores de 64 años que menores de 16 años y viceversa. Cuanto más alto es el índice, mayor es el envejecimiento de la población.

- Aumento de la Población Mayor y Subgrupos de Edad Avanzada

Dentro de los factores sociales nos encontramos con el aumento de la población mayor y subgrupos de edad avanzada, lo que se categorizaría como un factor demográfico de gran relevancia dentro de nuestro análisis. Las proyecciones oficiales del INE confirman esta tendencia. Como se aprecia en la Figura 9, se espera que para 2039 la población mayor de 65 años supere el 26% del total y que a mediados de siglo ronde el 30%. Esto significa que uno de cada tres españoles será mayor de 65 años en el horizonte de 2050.

Yendo más lejos, el subgrupo de mayor edad crece con fuerza, ya que las personas mayores de 80 años aumentarán un 47,5% en 15 años, pasando de 3 millones en 2024 a 4,34 millones en 2039. Incluso los centenarios prácticamente se triplicarán, pasando de 17 mil en 2024 a más de 49 mil en 2039 (Sosa Troya, 2024).

Figura 9. Proyección de la evolución del porcentaje de población mayor de 64 años en España



Fuente: Elaboración propia con los datos del INE (s.f.-g).

- Preferencia por Envejecer en Casa

Tradicionalmente, las residencias geriátricas, tanto públicas como privadas, han sido la opción institucional para mayores que no podían vivir solos, enfocados sobre todo en cuidados médicos y en dar asistencia continua. Sin embargo, en 2022, tan solo entre el 3% y el 4% de las personas mayores en España vivían en residencias, y estas son principalmente los que tienen un mayor grado de dependencia. La gran mayoría prefiere envejecer en casa con autonomía, pero con una casa adaptada a sus condiciones. Esta realidad, unida a los cambios demográficos y socioculturales ha dado un gran impulso al surgimiento de modelos alternativos de vivienda senior (Alonso, 2022).

- Salud y Autonomía de los Mayores

Según Alonso (2022), citando a Nuria Béjar, el 80% de los mayores de 65 años está en buen estado de salud, lo que indica que hay un mercado potencial considerable para servicios y viviendas adaptadas a personas mayores con cierto nivel de autonomía. Esta estadística subraya la creciente necesidad de viviendas que aboguen un estilo de vida activo y autónomo entre la población mayor.

Por otro lado, la soledad y el aislamiento social son reconocidos por la Organización Mundial de la Salud (OMS) como factores de riesgo clave para el desarrollo de afecciones de salud mental en etapas avanzadas de la vida. Según la OMS (2023), estas condiciones pueden aumentar el riesgo de depresión, ansiedad y deterioro cognitivo, además de tener un impacto negativo sobre la salud física, así como un mayor riesgo de enfermedades cardiovasculares y mortalidad prematura.

Por ello, resulta fundamental que las personas mayores no se sientan solas y tengan la oportunidad de vivir en comunidad, rodeadas de vínculos sociales significativos que favorezcan su bienestar emocional y su autonomía.

3.1.3 Factores políticos y legales

- Marco Legal y Regulatorio para Viviendas para Mayores

El marco legal para las viviendas destinadas a mayores en España está evolucionando para adaptarse a modelos innovadores como SilverHub. Las residencias tradicionales están reguladas estrictamente por la normativa de servicios sociales de cada Comunidad Autónoma, que establece requisitos como licencias, ratios de personal sanitario, y estándares de accesibilidad y seguridad. SilverHub, al operar posiblemente en un vacío normativo como "apartamentos con servicios" sin ofrecer cuidados sanitarios intensivos, podría necesitar una categorización especial bajo normativas emergentes como la Resolución 940/2022 en Madrid, que autoriza viviendas colaborativas como centros de acción social (Ayuntamiento de Madrid, 2022).

- Legislación Autonómica y Apoyo Institucional

Varias regiones en España están desarrollando legislación específica sobre viviendas colaborativas para seniors. Por ejemplo, la Comunidad Valenciana promulgó la Ley 3/2023 de Viviendas Colaborativas, la primera de su tipo en España, para fomentar

cooperativas de cesión de uso dirigidas a crear vivienda asequible y adaptada para mayores (BOE, 2023). Cada vez más se están apoyando modelos como el “*cohousing*” senior, ofreciendo subvenciones y facilitando el uso de suelo público para estos proyectos (Silver Economy Group, 2022).

- Regulaciones Urbanísticas y de Edificación

Todas las viviendas para mayores deben cumplir con el Código Técnico de Edificación, asegurando accesibilidad universal (rampas, ascensores anchos, baños adaptados, etc.) (Ministerio de vivienda y agencia urbana, s.f.). Además, los desarrolladores deben considerar las regulaciones urbanísticas que pueden incluir requisitos de dotaciones mínimas y posiblemente bonificaciones para proyectos orientados a mayores, lo cual influye significativamente en la viabilidad y costes de los proyectos.

3.1.4 Medioambientales

- Eficiencia Energética y Reducción de Recursos con Impacto Ambiental de la Prefabricación

Según Cao et al. (2015), la construcción de edificios residenciales de forma prefabricada no solo es significativamente más eficiente en el uso de la energía, logrando una reducción del 20,49% en el consumo total en comparación con la construcción tradicional, sino que también minimiza el agotamiento de recursos en un 35,82%, optimizando el uso de materiales como hormigón, acero y madera y reduciendo el desperdicio gracias a la precisión del ensamblaje. Además, esta técnica ofrece ventajas medioambientales adicionales, incluyendo una reducción del 6,61% en daños a la salud y del 3,47% en daños al ecosistema, consolidándose como una alternativa más sostenible y respetuosa con el medio ambiente frente a los métodos de construcción tradicionales.

- Reducción de Residuos en Construcción:

La prefabricación ayuda a reducir considerablemente los residuos generados en la construcción. Un estudio de Alireza (2022) encontró que este método puede disminuir el coste de los residuos en un 97,54% y lograr una reducción del 5,06% en el coste total del proyecto, evidenciando su eficacia en minimizar el impacto ambiental y económico de los residuos de construcción.

3.2 Microentorno – 5 Fuerzas de Porter

3.2.1 Rivalidad existente entre competidores

El crecimiento de la población mayor ha generado un mercado competitivo en la “*Silver Economy*”, intensificando la rivalidad entre los proveedores de servicios de atención a mayores, incluyendo salud, bienestar y vivienda adaptada, y forzando a las empresas a innovar y mejorar continuamente sus ofertas. Con la aparición de modelos alternativos como el “*cohousing*” y el “*coliving*” para mayores, esta rivalidad se ha intensificado aún más, pues estos nuevos modelos compiten indirectamente con las residencias geriátricas tradicionales ofreciendo entornos más atractivos y adaptados a las necesidades de independencia y socialización de los mayores. La amplia variación de precios entre provincias refleja una intensa rivalidad entre competidores en el mercado, donde los proveedores en áreas con precios altos pueden competir en calidad y servicios adicionales, mientras que en áreas más económicas la competencia puede centrarse en ofrecer opciones más asequibles (Geriatricarea, 2024).

Además, la variabilidad en los costes del suelo condiciona significativamente las decisiones estratégicas de las empresas, con algunas capaces de adquirir suelo en áreas de alto costo para ofrecer servicios premium, mientras que otras optan por regiones más económicas para captar una cuota de mercado diferente. En este contexto competitivo, los modelos como The Comm, la red Adorea impulsada por DomusVi y Ciudad Patricia representan la competencia más directa para SilverHub, demostrando una elevada demanda con listas de espera completas y expansiones planeadas para aumentar su capacidad (Conde, 2024; López Letón, 2021). Adorea combina la independencia con servicios hoteleros y sociosanitarios, ofreciendo flexibilidad de estancia y funcionando bajo un régimen de alquiler tradicional (Pareja, 2022), mientras que Ciudad Patricia en Benidorm ofrece un régimen de uso vitalicio de la vivienda, apelando especialmente a extranjeros y enfocándose en un nicho específico de mercado (López Letón, 2021).

Por otro lado, aunque los modelos de “*cohousing*” como Jubilar Villa Rosita, Trabensol, Walden XXI y Tartessos Málaga también presentan alternativas a las residencias tradicionales, se centran en fomentar la comunidad, la autonomía y la calidad de vida, atrayendo a un público activo y autónomo, similar a los perfiles potenciales de SilverHub, y responden al deseo común de evitar la soledad y vivir en entornos adaptados al envejecimiento activo. Pero requieren de compromisos previos, tiempo y capital

inicial, al tratarse de un modelo autogestionado, al tratarse de cooperativas de mayores que diseñan conjuntamente y gestionan su comunidad, disponiendo cada uno de su espacio individual privado, pero comparte zonas comunes, servicios y decisiones (Silver Economy Group, s.f.; Conde, 2024).

3.2.2 Amenaza de nuevos competidores

La tendencia demográfica hacia un aumento en la población de mayores está creando oportunidades atractivas para nuevos negocios interesados en entrar en el mercado de servicios y productos para mayores, lo que podría intensificar la competencia en este sector.

Aunque el modelo de *“cohousing senior”* puede presentar barreras de entrada relativamente bajas debido a su naturaleza cooperativa y autogestionada (porque no buscan competir con nadie, ya que son los propios socios los que van a vivir en el complejo), el *“coliving senior”* requiere inversiones significativas en infraestructura y servicios, además de tratarse de promotores externos que buscan atraer todos los clientes posibles. Lo que supone que se espere que haya barreras de entrada más elevadas en el *“coliving senior”*.

No obstante, la clara demanda en áreas con alta población envejecida, especialmente en ciudades como Madrid y Barcelona, junto con la variabilidad en la capacidad de pago, podría atraer a nuevos entrantes que ofrezcan modelos innovadores o más eficientes económicamente para capturar parte del mercado (Geriatricarea, 2024).

Los altos costes del suelo en áreas como Baleares y Madrid también representan una barrera significativa, mientras que las regiones con costes más bajos podrían ser más atractivas para explorar nichos de mercado menos saturados. Además, el mercado español de vivienda para mayores está ganando relevancia y diversidad, con operadores establecidos como DomusVi, Emeis, Ballesol, Amavir y Albertia, que, aunque centrados en cuidados asistenciales, compiten indirectamente con modelos como SilverHub que promueven una mayor autonomía. A su vez, la expansión y aceptación de los modelos de *“senior living”*, evidenciada por el aumento de proyectos que planean sumar casi 2.000 plazas residenciales para 2024, indican que el mercado está en expansión y podría atraer más entrantes nuevos actores, subrayando tanto la oportunidad como la amenaza de

nuevos competidores que pueden capitalizar sobre la creciente demanda de alojamientos alternativos para mayores (Conde 2024). Esto refleja un dinamismo en el sector que favorece la diversificación de la competencia y la innovación continua.

3.2.3 Poder de negociación de los proveedores

Los proveedores de productos para mayores y servicios de salud podrían ganar más poder de negociación a medida que aumenta la demanda de sus productos y servicios en un mercado en crecimiento, donde la población envejece. Esto les podría permitir determinar precios y términos de servicio más favorables.

Tanto el “*cohousing*” como el “*coliving*” para seniors dependen críticamente de diversos proveedores para servicios como restauración, limpieza y asistencia básica, lo que podría aumentar el poder de negociación de los proveedores especializados en estos servicios, especialmente si son pocos o si ofrecen opciones altamente diferenciadas. Además, los proveedores de servicios y bienes esenciales para el funcionamiento de las residencias pueden ejercer una influencia significativa en los precios finales, donde la capacidad de negociar costes favorables es crucial para mantener la competitividad, especialmente en regiones con alta competencia de precios.

De igual manera, los vendedores de suelo en regiones con alta demanda y precios elevados poseen un poder de negociación considerable, afectando las condiciones de compra y los márgenes de rentabilidad de los proyectos de desarrollo. Estos factores juntos refuerzan la importancia de los proveedores en la estructura de costes y la estrategia operativa en el mercado de vivienda para mayores.

3.2.4 Amenaza de servicios sustitutivos

La continua innovación en tecnología y servicios está introduciendo alternativas más eficientes y económicas para el cuidado y la atención de los mayores, lo que representa una amenaza significativa para los proveedores tradicionales de estos servicios. Existe una amenaza continua de productos sustitutivos, como servicios de asistencia domiciliar avanzada y tecnologías que permiten a los mayores vivir de manera independiente en sus hogares por más tiempo, lo que puede limitar la demanda de modelos residenciales específicos para seniors. Además, la disponibilidad de alternativas como el senior “*coliving*”, la atención domiciliar, y la tecnología de asistencia representa una amenaza

significativa para las residencias tradicionales, ya que estas opciones podrían ser más atractivas para seniors que buscan mantener su independencia y reducir costes, presionando a las residencias para adaptar sus modelos de negocio y estructuras de precios. La existencia de variabilidad en el coste del suelo urbano también ofrece a los desarrolladores la posibilidad de considerar alternativas de ubicación que puedan ofrecer un mejor equilibrio coste-beneficio, afectando la dinámica competitiva en el sector. Por último, los modelos de “*cohousing*”, que son autogestionados y no replicables a gran escala, implican procesos largos de implementación y compromisos significativos de tiempo y capital inicial por parte de los residentes. Aunque no representan una competencia directa para un modelo más estructurado y accesible como SilverHub, su crecimiento y la evolución en las preferencias culturales sobre cómo los mayores desean vivir su vejez los convierten en sustitutos relevantes que pueden influir en las decisiones del mercado

4. Posicionamiento estratégico

El posicionamiento estratégico de SilverHub es fundamental para asegurar su sostenibilidad y competitividad en el mercado. Dada su importancia, se va a definir el público objetivo, y se va a profundizar en la metodología analítica empleada para seleccionar las ubicaciones óptimas de los complejos. Ambas decisiones son cruciales para maximizar la propuesta de valor del proyecto, adaptándose a las necesidades reales de los residentes y asegurando una rentabilidad adecuada de las inversiones realizadas.

4.1 Público objetivo

El público objetivo de SilverHub se puede definir fácilmente debido a su modelo de negocio, que está enfocado en ofrecer una solución residencial para personas mayores activas que buscan calidad de vida, autonomía y un fuerte sentimiento de comunidad. El rango de edad óptimo de entrada al complejo se sitúa entre los 67 y 85 años, una etapa en la que las personas se jubilan y todavía gozan de buena salud, cierto grado de independencia y plena capacidad de decisión, pero comienzan a valorar entornos adaptados y seguros para envejecer con tranquilidad.

Aunque ese sea rango de edad para la entrada, la propuesta de valor de SilverHub está concebida para acompañar a los residentes a lo largo del tiempo, ofreciendo un entorno

que se adapta progresivamente a sus necesidades. Esto permite que envejecan en el mismo lugar, sin necesidad de cambiar de entorno ni romper los vínculos sociales creados en el complejo.

En resumen, el público objetivo de SilverHub está compuesto por personas de entre 67 y 85 años, con un cierto grado de independencia, pertenecientes a una clase media-alta, que buscan una vida socialmente activa, conectada y con propósito. Este perfil suele contar con pensión, ahorros o propiedades, lo que les permite acceder a modelos residenciales alternativos.

4.2 Análisis de datos para la selección de la ubicación

Uno de los aspectos más importantes para el desarrollo de este proyecto es determinar en qué ubicaciones se construirán los primeros complejos. Esta elección no solo influye en el funcionamiento logístico y económico del proyecto, sino también en su capacidad para captar una base de clientes lo suficientemente grande y asegurar un crecimiento estable a largo plazo.

4.2.1 Definición de los elementos del estudio

Para el presente estudio se ha construido una base de datos a partir de los datos más recientes de fuentes oficiales, que recopila indicadores demográficos y económicos de cada provincia con el fin de determinar qué provincias reúnen mejores características para la implementación de los complejos. SilverHub está enfocado en la población senior por lo que se han seleccionado variables que relejan la situación de las personas mayores y el contexto socioeconómico de cada provincia.

El “*dataset*” se compone de 13 variables y 49 observaciones (provincias), excluyendo Ceuta y Melilla para facilitar el análisis (no se han encontrado datos para todas las variables) y visualización:

- Tasa de dependencia: variable porcentual que indica la proporción de personas mayores de 64 años respecto a la población activa (16-64). Datos del INE (s.f.-h).
- Suelo urbano: variable numérica en euros que refleja el coste medio del suelo urbano. Datos del Ministerio de Transportes y Movilidad Sostenible (s.f.).
- Precio residencias: variable numérica en euros al mes que indica el precio medio

de cada plaza residencial. Datos de Geriatricarea (2024).

- Mayor 65 años: variable numérica que representa el número absoluto de personas mayores de 65 años. Datos de Geriatricarea (2024).
- Pensión: variable numérica en euros al mes que mide la pensión media que reciben los jubilados. Datos del Ministerio de Inclusión, Seguridad Social y Migraciones (2024).
- Índice de envejecimiento: variable porcentual que mide el número de personas mayores de 64 años por cada 100 menores de 16. Datos del INE (s.f.-c).
- Esperanza de vida: variable numérica en años que estima la longevidad media de la población, es decir, la esperanza de vida al nacer. Datos del INE (s.f.-a).
- # Pensiones viudedad: variable numérica que representa el número de pensiones de viudedad. Se va a utilizar como indicador indirecto de posibles situaciones de soledad. Datos del Ministerio de Inclusión, Seguridad Social y Migraciones (2024).
- # hogares unipersonales: variable numérica que indica el número de personas mayores de 65 años viviendo solas. Se va a utilizar como indicador del potencial grado de aislamiento. Datos del INE (s.f.-d).
- # alquiler: variable numérica que representa el número de viviendas alquiladas. Se va a utilizar como indicador de la predisposición de la población a modelos no basados en la propiedad. Datos del INE (s.f.-e).
- # hogares pagos pendientes: variable numérica que indica el número de hogares que están todavía en proceso de financiación, es decir, hogares comprados, pero con pagos pendientes. Permite inferir el nivel de endeudamiento y la capacidad de ahorro. Datos del INE (s.f.-e).
- # hogares pagados: variable numérica que indica la cantidad de viviendas están completamente pagadas. Datos del INE (s.f.-e).
- Ratio plazas residenciales: variable porcentual que muestra la oferta de residencias en relación con la población mayor, mide el número de plazas residenciales por cada 100 personas de 65 años o más. Permite detectar los territorios más saturados y aquellos donde puede haber una mayor oportunidad. Datos del CSIC (s.f.).

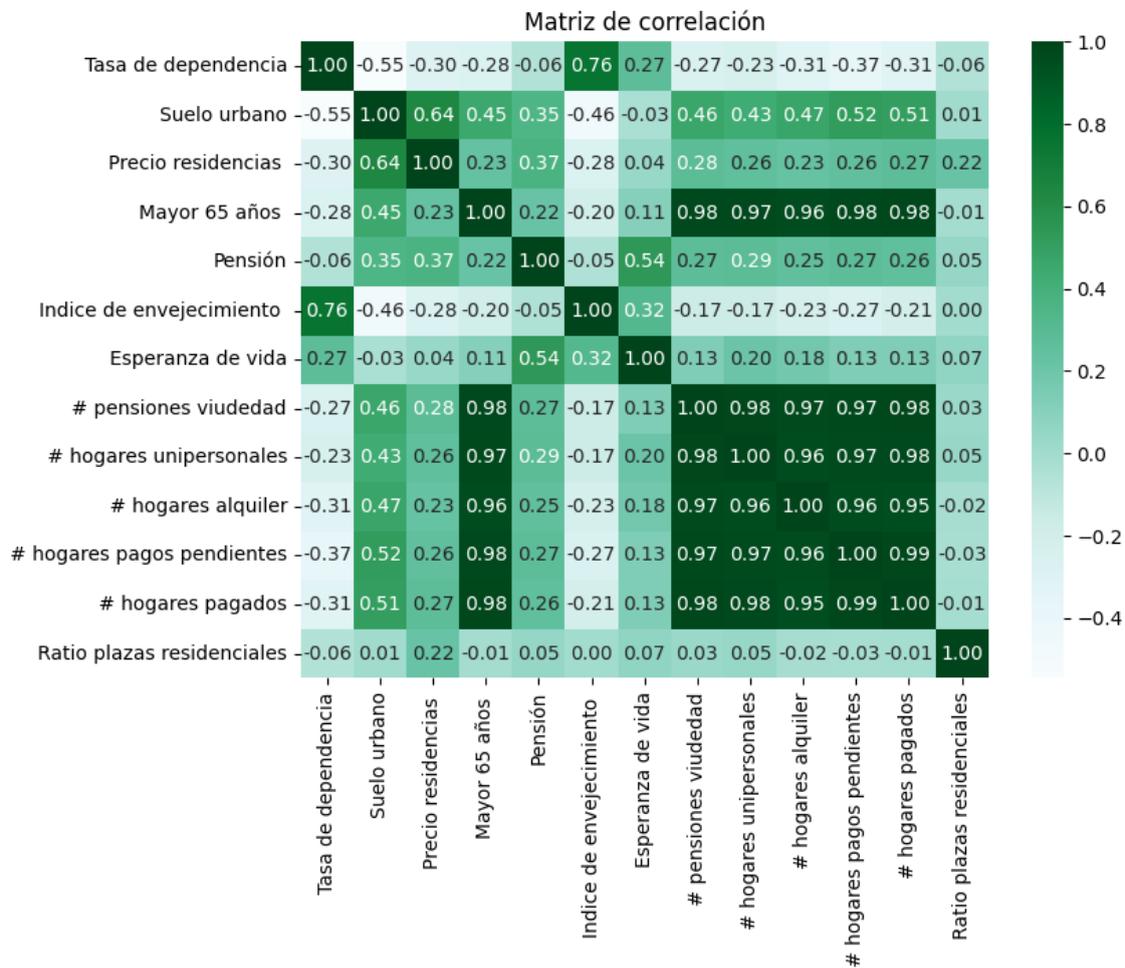
4.2.2 Análisis exploratorio y reducción de la dimensionalidad (PCA)

Cuando se hacen proyectos de análisis de datos, es común que haya que tratar con un gran número de variables, o lo que es lo mismo, con un gran número de dimensiones. En estos

casos, es probable que haya variables altamente correlacionadas, es decir, que haya información redundante. Esto puede llevar a una serie de problemas como la multicolinealidad, la conocida “maldición de la dimensionalidad”, o dificultades en la visualización de los datos, que se traduce en la dificultad para observar estructuras y patrones y, por ende, en la posibilidad de que se puedan extraer conclusiones.

Por ello, primero se va a llevar a cabo un análisis exploratorio en el que se va a analizar la correlación existente entre variables mediante la Figura 10:

Figura 10. Matriz de correlación

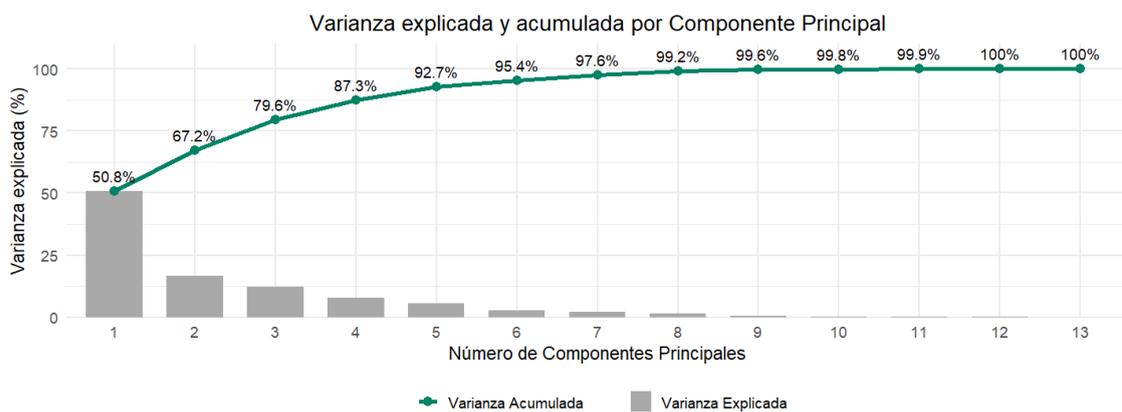


En esta la matriz, se puede observar una alta correlación entre algunas variables. Destaca especialmente la correlación que hay entre “Mayor 65 años”, “# pensiones viudedad”, “# hogares unipersonales”, “# hogares alquiler”, “hogares pagos pendientes” y “# hogares pagados”, siendo superior a 0.94. Esto implica que existe redundancia entre las variables, lo que puede derivar en problemas de multicolinealidad, dificultando la interpretación de los resultados y afectando negativamente al rendimiento del análisis.

Para solucionar este problema, se va a aplicar una técnica de “*machine learning*” de reducción de dimensionalidad llamada Análisis de Componentes Principales (PCA, por sus siglas en inglés). Esta técnica transforma las variables originales en un nuevo conjunto de variables sintéticas, denominadas componentes principales, que son ortogonales entre sí y que capturan la mayor parte de la varianza (información) presente en los datos. De este modo, se consigue reducir la complejidad del conjunto de datos, eliminar redundancias, mitigar los problemas derivados de la multicolinealidad y facilitar tanto la visualización como el análisis posterior.

A continuación, se va a graficar la varianza explicada y acumulada para ver cuánta información recoge cada componente principal:

Figura 11. Varianza Explicada y Acumulada por Componente Principal



Nota: La varianza explicada se ha calculado mediante la siguiente fórmula:

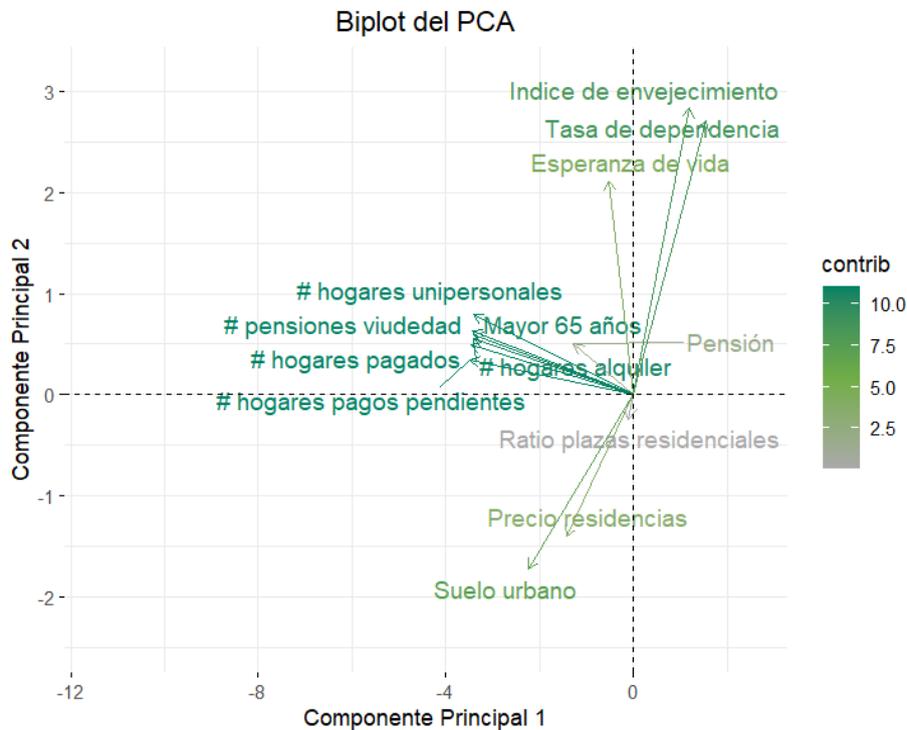
$$\text{Varianza Explicada} = \frac{(\text{desviación típica}_k)^2}{\sum_{j=1}^p (\text{desviación típica}_j)^2}$$

Según la Figura 11, necesitaríamos al menos cinco componentes principales para poder recoger más de un 90% de la información. Sin embargo, la quinta componente principal solo añade alrededor de un 5% de varianza explicada, por lo que no compensa añadir una dimensión más para ganar ese porcentaje de información adicional. Por lo tanto, se continuará con cuatro componentes principales para conservar más de un 87% de la información contenida en las variables originales.

Para ver cómo se relacionan las variables entre sí y con las dos primeras componentes principales (que son las que recogen la mayor parte de la información), se ha realizado un

“biplot” en la Figura 12:

Figura 12. “Biplot” del PCA



Nota: Las flechas en la misma dirección señalan correlaciones positivas, mientras que las opuestas indican correlaciones negativas, y la escala de color “contrib” mide el peso de cada variable en estas dos componentes.

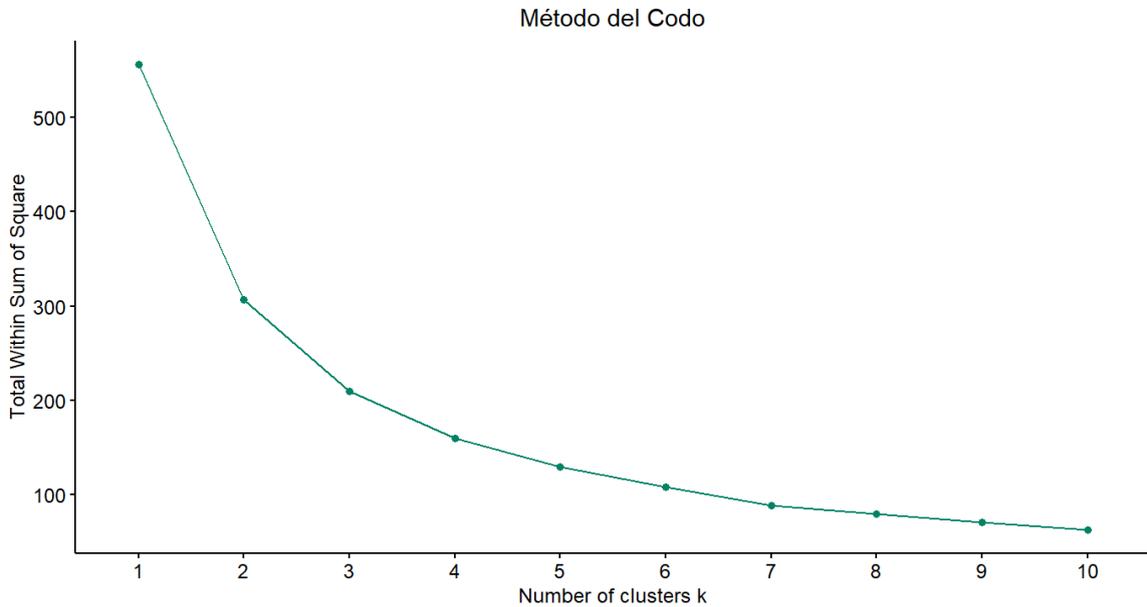
Pese a que el “biplot” resulta una herramienta muy útil para visualizar las relaciones entre las variables y las dos primeras componentes principales del PCA, en nuestro análisis se han requerido cuatro componentes principales para capturar alrededor de un 87% de la variabilidad de los datos. Por lo tanto, hay que tener en cuenta que, este “biplot”, solo refleja una parte de la estructura completa de la información, es decir, aunque las dos primeras dimensiones aportan la mayor parte de información, el resto de componentes principales contienen datos adicionales que no se están plasmando en esta visualización. Sin embargo, el “biplot” sigue siendo útil porque nos permite tener una idea general de cómo interactúan las variables en estas dos dimensiones.

4.2.3 Selección del número de “clusters”

Una vez seleccionadas las componentes principales que se utilizarán en el análisis, y con el objetivo de aplicar “clustering”, se procede a determinar el valor óptimo del hiperparámetro k, correspondiente al número de “clusters”. Para ello, se emplean tres

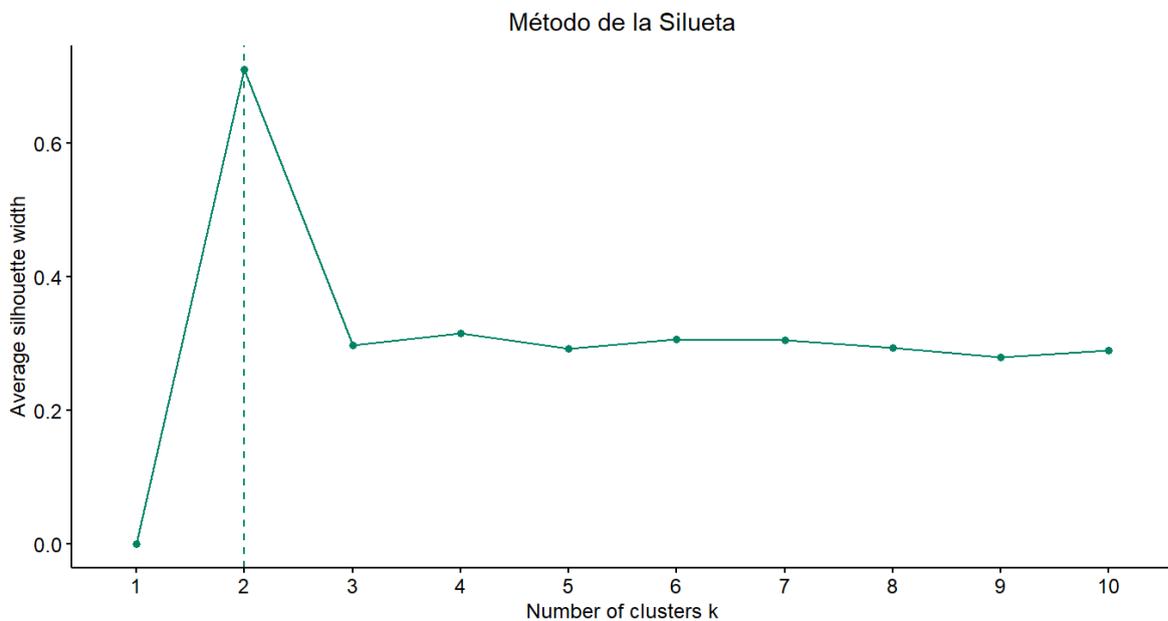
métodos complementarios que se utilizan con frecuencia para esta función: el método del codo (Figura 13), el método de la silueta (Figura 14) y el análisis visual del dendrograma que se utilizará para hacer “*clustering*” jerárquico (Figura 15).

Figura 13. Método del Codo



Nota: El método del codo estima el número óptimo de “*clusters*” (k) evaluando la variación “*intra-cluster*”, medida por el “*Within-Cluster Sum of Squares*”. El “codo” indica el punto a partir del cual añadir más “*clusters*” apenas mejora la dispersión del grupo.

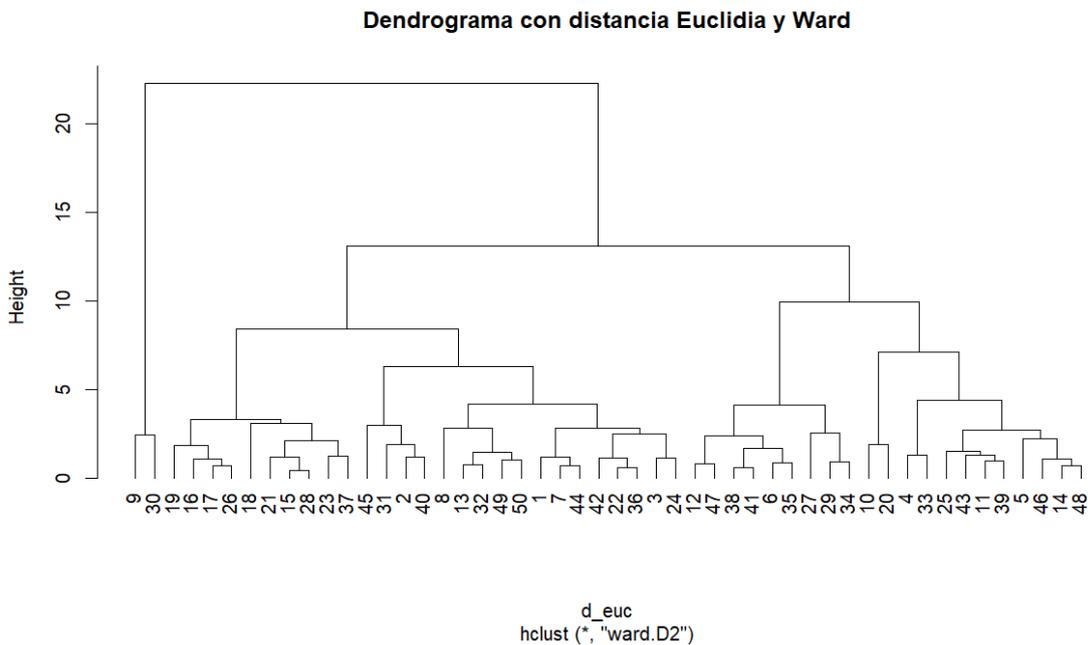
Figura 14. Método de la silueta



Nota: El método de la silueta establece que el número óptimo de “*clusters*” es el que maximiza el valor medio de los índices de la silueta. La silueta media es un valor que se encuentra entre -1 y 1. Cuando es cercano a 1, indica que la observación se ha asignado al “*cluster*” de manera correcta. Por otro lado, si el valor es cercano a 0, indica que la observación está entre dos “*clusters*”. Por último, si la observación es

negativa probable que esté asignada incorrectamente al “cluster”.

Figura 15. Dendrograma con distancia Euclídea y enlace de Ward

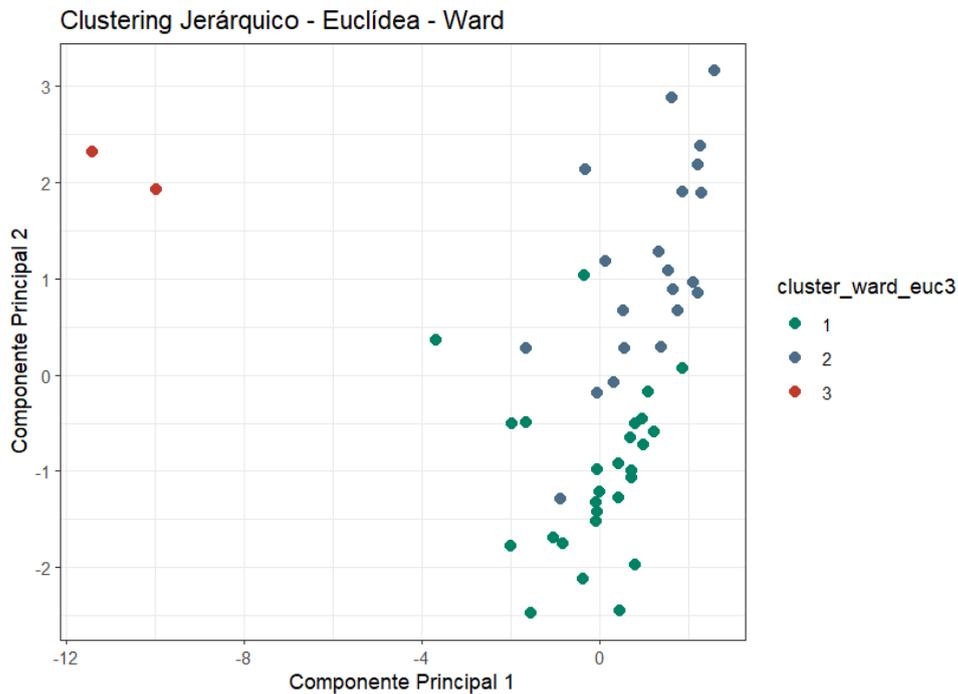


El método del codo representado en la Figura 13, sugiere que el número óptimo de “clusters” podría situarse en $k = 4$, ya que añadir más grupos no reduce significativamente la variación “intra-cluster”. Por otro lado, el método de la silueta de la Figura 14 muestra que la silueta media alcanza su máximo con $k = 2$, indicando que dos grupos ofrecen la mejor combinación entre cohesión interna y separación respecto a los demás “clusters”. No obstante, se descarta la opción de seleccionar únicamente dos “clusters”, ya que una segmentación tan reducida no permitiría capturar matices relevantes entre las observaciones ni aportar un nivel de detalle suficiente para que el análisis resulte útil desde una perspectiva práctica. Habiendo descartado la alternativa de escoger dos “clusters”, el dendrograma de la Figura 15 sugiere que una segmentación en tres “clusters” podría ser apropiada.

4.2.4 “Clustering”

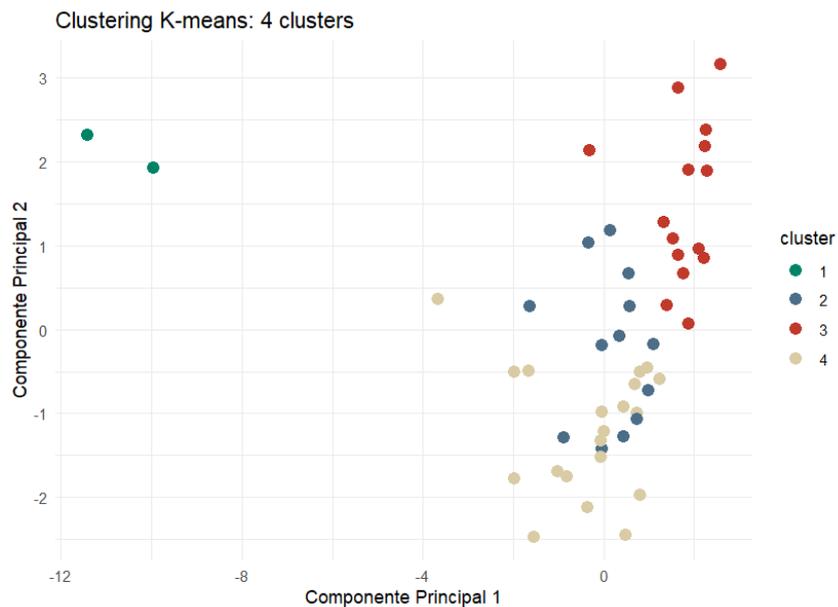
Una vez analizado el número óptimo de “clusters” mediante los tres métodos más habituales, se va a llevar a cabo un análisis que compare la alternativa propuesta por el método del codo de hacer un “*k-means*” con 4 “clusters” y la sugerida por el dendrograma de hacer un “clustering” jerárquico con 3 “clusters”:

Figura 16. Visualización del “clustering” jerárquico con 3 grupos en 2 dimensiones



Nota: Esta visualización se realiza sobre las dos primeras componentes principales, lo cual no refleja de forma completa la estructura subyacente de los datos porque se han utilizado cuatro componentes principales para la realización del análisis. Por tanto, una representación bidimensional puede generar una percepción distorsionada del agrupamiento, ya que omite información relevante contenida en las componentes restantes.

Figura 17. Visualización del “clustering” con “k-means” con k=4 en 2 dimensiones



Nota: Esta visualización se realiza sobre las dos primeras componentes principales, lo cual no refleja de

forma completa la estructura subyacente de los datos porque se han utilizado cuatro componentes principales para la realización del análisis. Puede parecer que está peor clasificada que la anterior, pero no es así porque no se están teniendo en cuenta visualmente las otras dos dimensiones restantes.

Figura 18. Gráfico de la silueta del “clustering” jerárquico

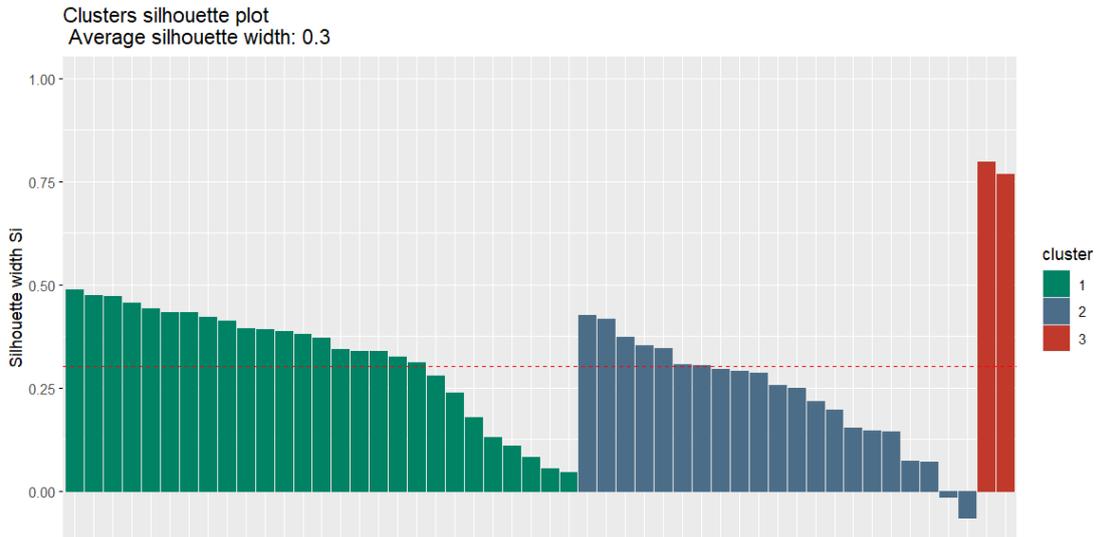
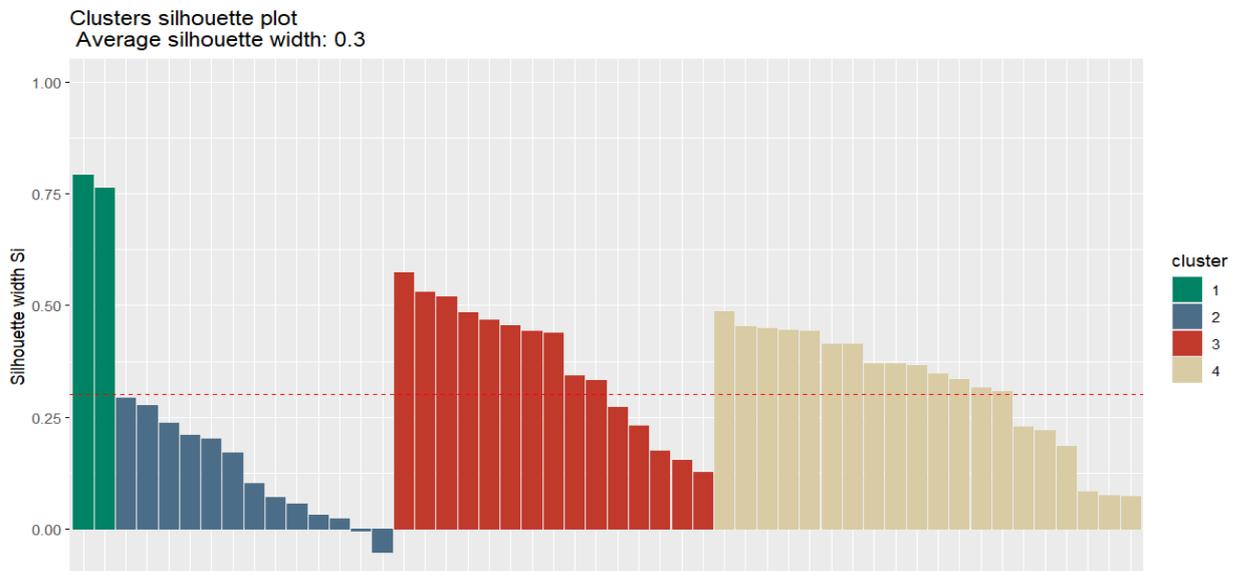


Figura 19. Gráfico de la silueta de “clustering” con “k-means”



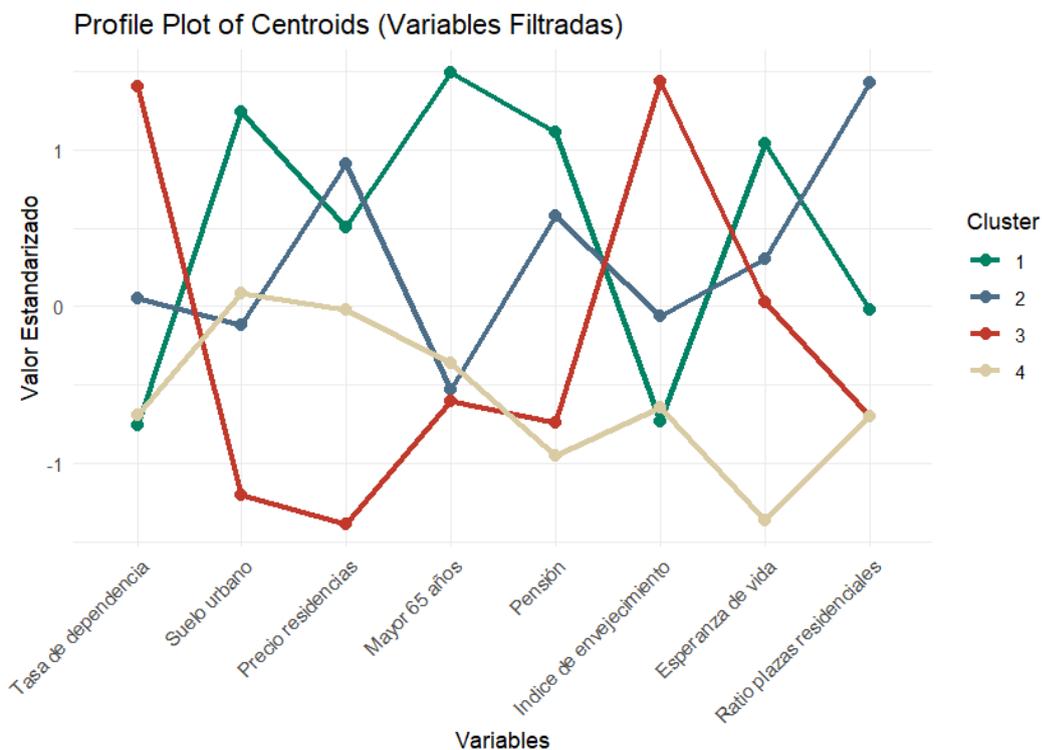
Tanto el “clustering” jerárquico con tres “clusters” como el “k-means” con cuatro, muestran únicamente dos observaciones mal asignadas, y en ambos casos se obtiene una anchura media de silueta de 0,3. Si bien este valor no alcanza niveles considerados óptimos (generalmente por encima de 0,5), sí proporciona una orientación válida dada la complejidad de la estructura de los datos, la cual dificulta una separación totalmente nítida

entre grupos. En este contexto, se opta finalmente por emplear el algoritmo “*k-means*” con cuatro “*clusters*”. Esta elección responde a la necesidad de una segmentación suficientemente detallada, lo que permite diferenciar con mayor claridad los perfiles territoriales, sin que la calidad de la clasificación se vea comprometida en exceso. Además, ofrece un equilibrio adecuado entre la interpretabilidad y la capacidad de distinguir oportunidades y patrones relevantes para la planificación de complejos residenciales en el ámbito del envejecimiento poblacional, en línea con los objetivos analíticos de este trabajo.

4.2.5 Evaluación de perfiles y selección final de la ubicación

Una vez definido y evaluado el “*clustering*”, se procede a describir el perfil medio de cada grupo. Para ello, se ha elaborado un “*profile plot*” de los centroides (Figura 20), que representa la media estandarizada de cada variable en cada uno de los cuatro “*clusters*” identificados. Dicho gráfico ofrece una visión comparativa de las características más destacadas de cada grupo, facilitando la interpretación de las diferencias y similitudes entre ellos.

Figura 20. “*Profile plot of centroids*”



Nota: Antes de realizar esta visualización, se han eliminado las variables “# pensiones viudedad”, “#

hogares unipersonales”, “# hogares de alquiler”, “hogares pagos pendientes” y “# hogares pagados”, debido a que presentaban una correlación muy alta con la variable “Mayores de 65 años”, lo que provocaba una redundancia informativa que podía distorsionar la interpretación de los perfiles.

Figura 21. Tabla de asignación de las provincias a cada “cluster”

Table: Asignación de Provincias por Cluster

Cluster 1	Cluster 2	Cluster 3	Cluster 4
08 Barcelona	01 Araba/Álava	33 Asturias	02 Albacete
28 Madrid	48 Bizkaia	05 Ávila	03 Alicante/Alacant
NA	39 Cantabria	09 Burgos	04 Almería
NA	12 Castellón/Castelló	10 Cáceres	06 Badajoz
NA	15 Coruña, A	16 Cuenca	07 Balears, Illes
NA	20 Gipuzkoa	22 Huesca	11 Cádiz
NA	17 Girona	24 León	13 Ciudad Real
NA	19 Guadalajara	27 Lugo	14 Córdoba
NA	25 Lleida	32 Ourense	18 Granada
NA	31 Navarra	34 Palencia	21 Huelva
NA	26 Rioja, La	37 Salamanca	23 Jaén
NA	47 Valladolid	40 Segovia	29 Málaga
NA	50 Zaragoza	42 Soria	30 Murcia
NA	NA	44 Teruel	36 Pontevedra
NA	NA	49 Zamora	41 Sevilla
NA	NA	NA	43 Tarragona
NA	NA	NA	45 Toledo
NA	NA	NA	46 Valencia/València
NA	NA	NA	35 Las Palmas
NA	NA	NA	38 Tenerife

El análisis del gráfico (Figura 20), junto con la tabla de asignación de provincias (Figura 21), permite identificar y etiquetar los “clusters” en función de su atractivo estratégico para el modelo SilverHub:

- **“Cluster” 1, Núcleos Urbanos Premium:** Incluye únicamente a Madrid y Barcelona. Este grupo se caracteriza por pensiones elevadas, gran población mayor de 65 años, alta esperanza de vida y un coste del suelo alto. Aunque la inversión inicial sería elevada, la capacidad económica y la potencial demanda hacen de estas ubicaciones áreas estratégicas ideales para el modelo SilverHub.
- **“Cluster” 2, Regiones Consolidadas con Potencial:** Comprende provincias como Álava, Vizcaya, Cantabria o Castellón. Presenta un perfil medio-alto en la mayoría de las variables. Cabe destacar el alto el precio de las residencias y de la pensión recibida, lo que permitiría ofrecer un precio elevado para SilverHub. Sin embargo, también presenta un elevado ratio de plazas residenciales, lo que demuestra que hay más oferta que en el resto de “clusters”. Estas provincias representan una oportunidad realista de expansión, siempre que la propuesta de valor esté bien diferenciada y adaptada al contexto local.
- **“Cluster” 3, Zonas de Demanda no Satisfecha:** Está compuesto por provincias como Palencia, Zamora o Ávila. Presenta valores medios en el coste del suelo precio

de las residencias y población mayor de 65 años e índices bajos en el resto de las variables. La viabilidad de proyectos como SilverHub parece limitada, aunque podría llegar a ser una oportunidad porque hay poca oferta de plazas residenciales.

- **“Cluster” 4, Territorios de Crecimiento Potencial:** Reúne provincias como Jaén, Toledo, Albacete o Pontevedra. Se caracterizan por tasas muy elevadas de envejecimiento y dependencia, aunque presentan valores bajos en el resto. Este cluster refleja regiones menos atractivas a corto plazo, pero con potencial de desarrollo a medio-largo plazo debido a las provincias que incluye.

Esta segmentación territorial permite establecer una hoja de ruta estratégica para SilverHub. La elección de Madrid y Barcelona como puntos de partida responde a una lógica de maximización del impacto y consolidación de marca en las dos regiones con mayor atractivo global para el modelo.

5. Estructura financiera y proyecciones

Una vez analizada la segmentación territorial a través del “*clustering*” y definido el perfil estratégico de las distintas agrupaciones, se ha determinado que Madrid y Barcelona, serán las localizaciones iniciales para la implantación de los dos primeros complejos SilverHub.

A partir de esta selección, el presente capítulo tiene como objetivo estimar la estructura de ingresos y costes asociada a la implementación del modelo SilverHub en estas dos regiones. Para ello, se ha optado por utilizar la simulación de Monte Carlo.

La simulación Monte Carlo es una técnica estadística utilizada para modelar sistemas complejos bajo condiciones de incertidumbre. Se basa en el uso de valores aleatorios y distribuciones de probabilidad para simular una gran variedad de escenarios posibles y calcular así un rango de resultados probables (Crum y Rayhorn, 2019). De esta manera, es posible cuantificar la incertidumbre inherente a variables críticas como puede ser la tasa de ocupación, el número de unidades disponibles, el precio del alquiler o los costes operativos, entre otras.

5.1 Fuentes de ingresos

Para estimar los ingresos que generará SilverHub a través de los complejos piloto en

Madrid y Barcelona, es necesario establecer una serie de supuestos de partida. Estos supuestos son fundamentales, ya que configuran el marco sobre el cual se construye el modelo financiero y condicionan de manera directa los resultados obtenidos en el análisis. Las estimaciones son las siguientes:

- Número de viviendas: Se estima construir un rango de entre 100 y 150 viviendas por complejo. Este tamaño permite alcanzar una escala suficiente para ofrecer servicios comunitarios (como comedor, gimnasio o atención sociosanitaria) de forma eficiente, sin generar una sensación de masificación.
- Plazos: se va a asumir un período estimado de dos años hasta la entrada de los primeros residentes en los complejos SilverHub. Este intervalo contempla tanto la obtención de las licencias administrativas necesarias como el proceso de construcción de los complejos.
- Reservas: durante los dos años en los que se tramitan las licencias y se ejecuta la construcción, los usuarios podrán reservar su plaza. Se van a determinar tres escenarios:
 - Pesimista: entre el 25% y 50% de las viviendas serán reservadas.
 - Neutro: entre el 50% y 75% de las viviendas serán reservadas.
 - Optimista: entre el 75% y 90% de las viviendas serán reservadas.
- Tasa de ocupación: dada la fuerte demanda potencial en el sector de los mayores, se podría asumir una alta tasa de ocupación, pero por prudencia se ha decidido plantear tres escenarios:
 - Pesimista: en el que se esperaría una tasa de ocupación de 60%-70%.
 - Neutro: en el que se esperaría una tasa de ocupación de 70%-90%.
 - Optimista: en el que se esperaría una tasa de ocupación de 90%-100%.
- Precios: el modelo va a ofrecer dos planes:
 - Plan Básico: incluye el acceso a la vivienda y a todas las zonas comunes del complejo como puede ser el gimnasio. El precio se va a encontrar dentro del siguiente rango: 2000-2400€/mes.
 - Plan Premium: incluye el plan básico y acceso a la asistencia especializada, como pueden ser los enfermeros o los fisioterapeutas. El precio va a estar dentro del siguiente rango: 2600-2800€/mes
- Evolución del plan elegido: se va a asumir que, en los primeros años, los residentes

van a tener preferencia por el plan básico porque es cuando son más independientes y no tienen necesidad de asistencia especializada. Pero a medida que pasan los años, van a ir necesitando más dicha asistencia. Por lo tanto, se estima la evolución del plan elegido de la siguiente manera:

- Años 1-5: 80% básico / 20% premium
 - Años 6-10: 65% básico / 35% premium
 - Años 11-15: 50% básico / 50% premium
 - Años 16-20: 40% / 60% premium
- Tasa de mantenimiento de la comunidad: se añadirá una cuota mensual comunitaria de 100-150 €/mes para cubrir gastos de mantenimiento como puede ser para jardinería o limpieza de zonas comunes, entre otros.

Una vez definida la estructura de ingresos del modelo SilverHub, se ha desarrollado una simulación Monte Carlo con el objetivo de proyectar la evolución de los ingresos a lo largo de 20 años. Esta simulación tiene en cuenta tanto la incertidumbre inherente al proyecto como las distintas condiciones del mercado, para lo cual se han planteado tres escenarios: pesimista, neutro y optimista.

A continuación, se detallan los resultados obtenidos para cada uno de los escenarios:

- Pesimista: se asume una tasa de ocupación de entre el 60 % y el 70 %, con una tasa de reservas inicial baja (25 %–50 %) y predominancia del plan básico. Los ingresos anuales, tras los dos primeros años de reservas (0,05 M€ anuales), se estabilizan a partir del año 3 en torno a los 5,0–5,2 millones de euros, alcanzando una media de 5,25 M€ en el año 20. En términos acumulados, el modelo proyecta unos ingresos medios de 91,78 millones de euros al final del periodo, con un percentil 5 superior a los 75 millones, lo que demuestra una cierta robustez del modelo incluso en condiciones desfavorables.
- Neutro: Con una tasa de ocupación más elevada (70 %–85 %) y una tasa de reservas del 50 %–75 %, este escenario representa un punto medio entre los extremos. A partir del año 3, los ingresos anuales se sitúan entre 5,7 y 6,2 millones de euros, reflejando el efecto positivo de una mayor adopción del plan premium. Los ingresos acumulados en este caso alcanzan una media de 108,14 millones de euros en el año 20. El percentil 5 se sitúa en 88,66 millones, lo que garantiza ingresos sostenibles incluso en

situaciones menos favorables dentro del escenario medio.

- Optimista: Este escenario plantea la situación más favorable, con una ocupación del 90 %–100 % y reservas previas del 75 %–90 %, además de una mayor proporción de usuarios optando por el plan premium a lo largo del tiempo. A partir del año 3, los ingresos anuales se sitúan en torno a los 6,9–7,5 millones de euros, alcanzando los 7,49 M€ en el año 20. La media acumulada al final del horizonte temporal asciende a 130,84 millones de euros, con un percentil 95 de 154,48 millones, lo que ilustra el elevado potencial económico del modelo en un contexto de fuerte demanda.

Por lo tanto, el modelo presenta resultados estables, realistas y coherentes bajo los tres escenarios analizados (pesimista, neutro y optimista). No se han detectado valores extremos ni inconsistencias significativas, lo que refuerza la solidez de los supuestos utilizados y la validez del enfoque probabilístico aplicado.

Las reservas iniciales, aunque no representan un volumen significativo de ingresos, permiten activar el flujo de caja durante los dos años previos a la operación, aportando liquidez al proyecto en una fase crítica. Esta característica mejora el perfil financiero del modelo desde el inicio.

En términos acumulados, los ingresos proyectados oscilan entre 91,78 millones de euros en el escenario pesimista y 130,84 millones de euros en el optimista, con el escenario neutro situándose en torno a los 108,14 millones de euros. Esta diferencia de casi 40 millones de euros entre los extremos pone de manifiesto la sensibilidad del modelo a la tasa de ocupación y a la distribución entre planes básico y premium, variables que deben ser gestionadas estratégicamente desde la perspectiva comercial y operativa.

En definitiva, los resultados de la simulación validan la viabilidad financiera del modelo SilverHub, siempre que se logre mantener una ocupación mínima del 60 % y se potencie el valor añadido del plan premium. El análisis confirma también la importancia de maximizar tanto la tasa de ocupación como el valor percibido por los residentes, ya que ambos factores impactan de manera directa en la rentabilidad a largo plazo del proyecto.

Figura 22. Simulación de ingresos interanuales por escenario

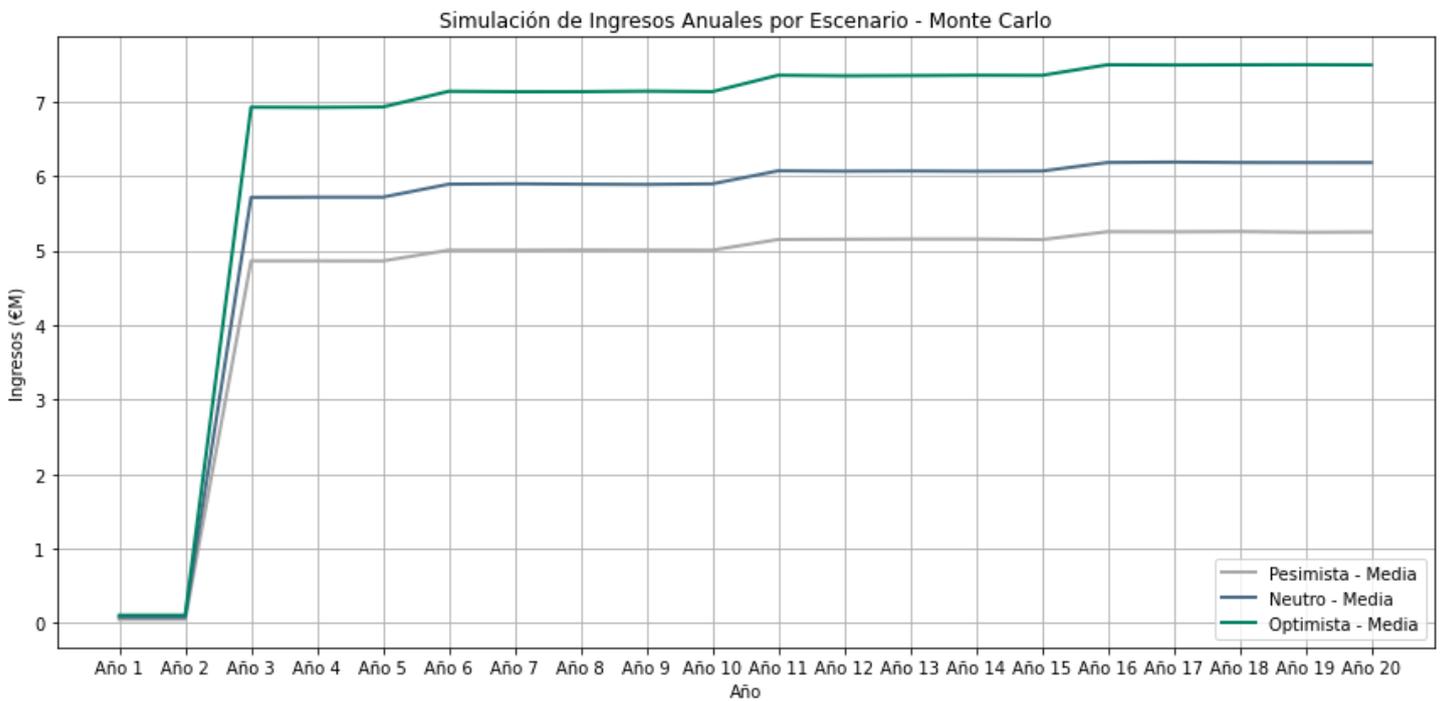
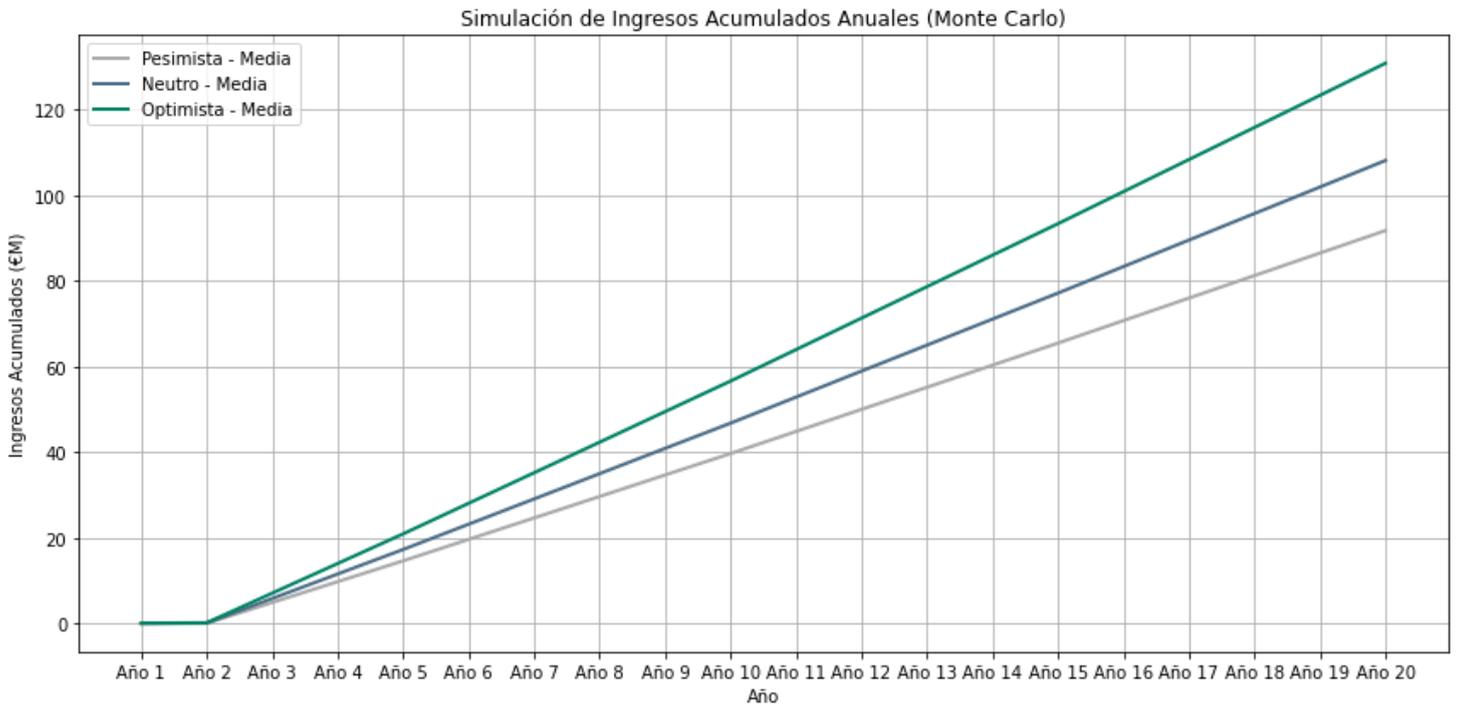


Figura 23. Simulación de ingresos acumulados por escenario



5.2 Costes esperados

En la misma línea que en los ingresos, para estimar los costes también se van a establecer una serie de asunciones. Estas suposiciones permiten construir un modelo financiero

coherente y adaptado a la realidad del proyecto, contemplando rangos realistas ante la incertidumbre existente. Las estimaciones son las siguientes:

- Terreno: se van a utilizar los datos del Ministerio de Transportes y Movilidad (2024) para poner precio al terreno. Por lo tanto, para Madrid será 306,7€/m² y para Barcelona 204,2€/ m². Una vez determinado el precio por metro cuadrado, es necesario establecer cuántos metros cuadrados serán necesarios para construir el complejo. Se va a proponer un rango de entre 15.000 y 20.000 metros cuadrados.
- Casas prefabricadas: según Martínez (2025), el precio medio del metro cuadrado de una casa prefabricada puede estar entre 1.200 y 2.500 €/ m², aunque puede ser inferior dependiendo de la compañía y del proyecto. Para este análisis se va a utilizar ese rango.
- Servicios comunitarios: se ha estimado precio de 550.000 – 940.000 euros para la instalación de todas las zonas comunes (comedor y cocina, gimnasio, centro de fisioterapia y rehabilitación, espacios de socialización, etc.)
- Licencias y tasas: se estima un coste total de entre 40.000 y 60.000 euros para cubrir las licencias urbanísticas, tasas municipales, permisos de obra y otros trámites administrativos necesarios para la construcción y puesta en marcha de los dos complejos

Para los costes del terreno, casas prefabricadas, los servicios comunitarios, y las licencias y tasas se va a asumir que se pagan en los dos años de duración previos a la entrada de los residentes en los que tiene lugar la construcción y tramitación de licencias.

- Vida útil del terreno: se va a asumir una vida útil de entre 40 y 50 años para amortizar la inversión inicial e instalaciones.
- Gasto de personal: se han considerados perfiles como enfermeros, fisioterapeutas, cocineros, personal de limpieza, monitores deportivos y personal de seguridad/conserjería. Se estima que el gasto total anual en personal sea de 650.000 – 900.000 €
- Otros gastos operativos: aquí se van a incluir los costes administrativos y de gestión, marketing y captación de residentes, asesoría legal y fiscal, el seguro de los complejos, entre otros. Se estima que el total esté entre 160.000 y 220.000€ al año.

Para la estructura de costes, también se ha implementado una simulación Monte Carlo

para proyectar su evolución a lo largo de los 20 años de análisis. Esta simulación considera tanto los costes iniciales (terreno, licencias, casas prefabricadas y servicios comunitarios) como los costes operativos anuales (personal, servicios generales y mantenimiento), así como la amortización progresiva de la inversión inicial.

El modelo proyecta unos costes anuales estables tras la fase de inversión inicial. Durante el primer año, los costes corresponden exclusivamente a licencias y tasas, con una media cercana a los 50.000 euros. En el segundo año, se registra un incremento significativo con una media de 33 millones de euros, debido a la adquisición de terrenos, la construcción de viviendas prefabricadas y la instalación de los servicios comunes. A partir del año 3, los costes se estabilizan en torno a 1,92 millones de euros anuales, lo que refleja los gastos operativos corrientes junto con la amortización del capital invertido.

La homogeneidad en los años operativos refleja un modelo sólido y realista, sin grandes oscilaciones que puedan comprometer la viabilidad financiera del proyecto.

En cuanto a los costes acumulados, se observa un crecimiento pronunciado en los dos primeros años, alcanzando una media de 33 millones de euros al finalizar el segundo año. A partir de ahí, el incremento se produce de manera estable, llegando a los 67 millones de euros acumulados al término del vigésimo año. Esta cifra se mantiene dentro de los rangos esperados y es coherente con el dimensionamiento de los complejos y los servicios ofrecidos.

La diferencia entre el percentil 5 y el percentil 95 se mantiene relativamente constante en todos los años, lo cual sugiere una baja dispersión en los resultados y, por tanto, un nivel de incertidumbre controlado en las proyecciones.

Los resultados obtenidos mediante esta simulación validan la solidez del modelo de costes de SilverHub. La principal carga financiera se concentra en el segundo año, correspondiente a la inversión inicial necesaria para la puesta en marcha del proyecto. Posteriormente, el mantenimiento del servicio se puede sostener con una estructura de costes predecible y estable.

La progresividad del modelo, junto con su bajo nivel de variabilidad interanual, facilita la planificación financiera a medio y largo plazo. Esto resulta especialmente relevante en proyectos con alta intensidad de capital inicial como SilverHub, ya que permite a los

inversores y gestores anticipar los flujos de caja y dimensionar adecuadamente las necesidades de financiación.

Figura 24. Simulación de costes interanuales por escenario

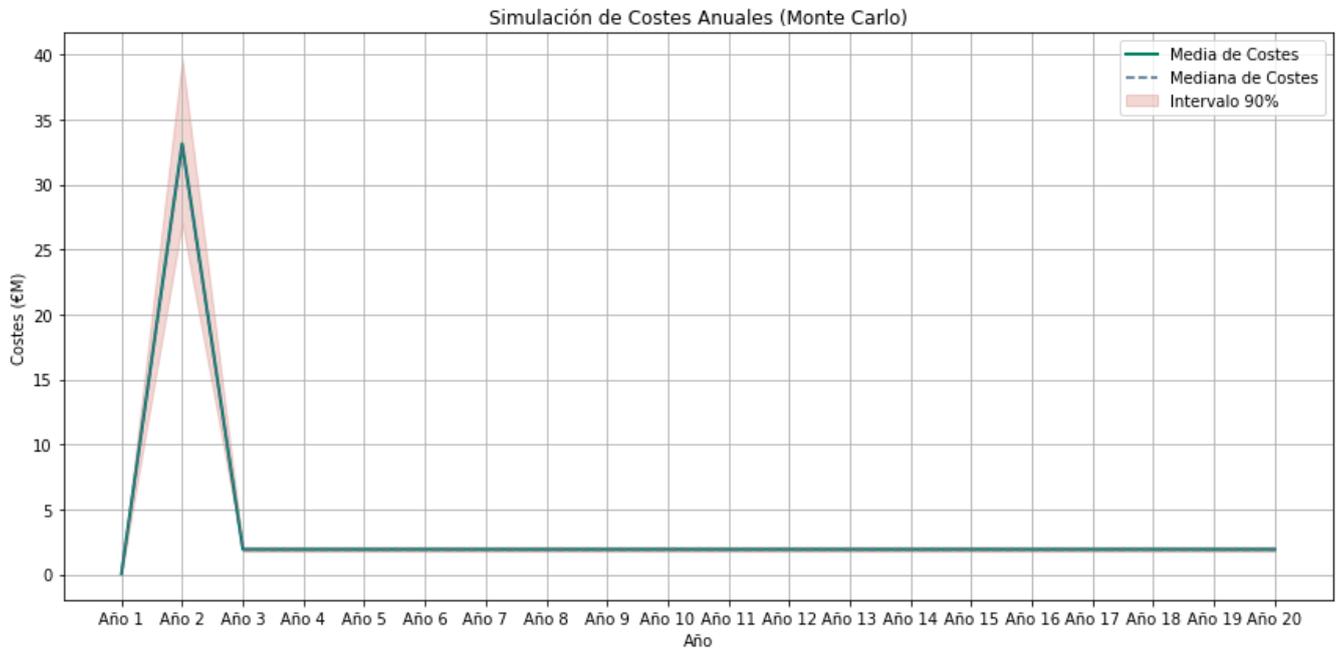
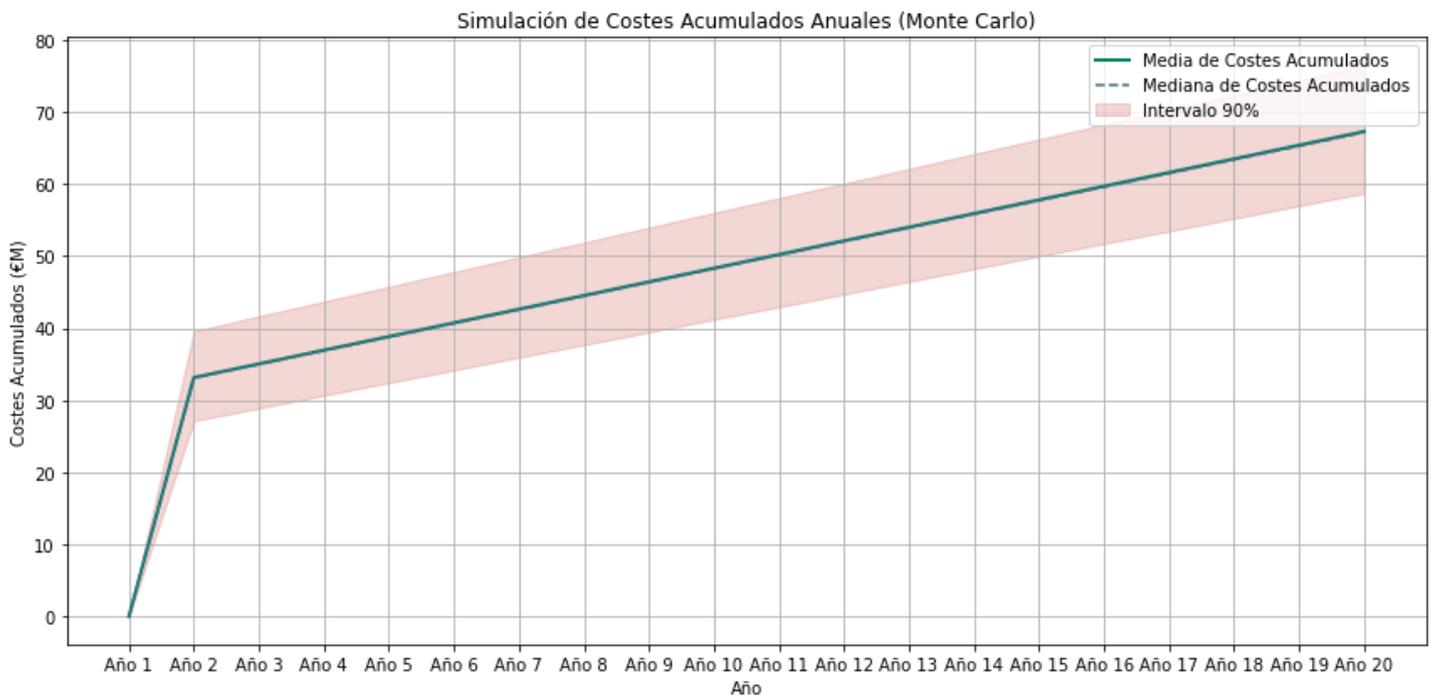


Figura 25. Simulación de costes acumulados por escenario



5.3 Resultados del proyecto

Una vez establecida la estructura de ingresos y costes del modelo SilverHub, se ha

procedido a estimar los beneficios también a lo largo de 20 años, con el fin de observar la evolución de los beneficios operativos (ingresos menos costes de la actividad de SilverHub) bajo tres escenarios establecidos:

- Pesimista: los beneficios anuales comienzan siendo negativos debido a los elevados costes de inversión inicial (año 2) y al desajuste entre ingresos y costes operativos durante los primeros años de funcionamiento. El punto de equilibrio se encuentra en el año 14, manteniéndose estables desde ese punto con una media de en torno a 3,36 millones de euros por año. Al finalizar el horizonte de análisis (año 20), el beneficio acumulado medio alcanza los 24,49 millones de euros, con un rango entre 15,71 y 33,65 millones según el percentil 5 y 95. Esto demuestra que, incluso en un escenario adverso, el modelo puede recuperar la inversión y ser rentable a largo plazo, aunque con un periodo de recuperación más lento.
- Neutro: el beneficio acumulado logra compensar la inversión inicial y se vuelve positivo a partir del año 11, cuando se registra un beneficio medio de 2,64 millones de euros. Este margen mejora progresivamente hasta alcanzar 40,78 millones de euros en el año 20, con un intervalo entre 28,07 y 54,86 millones de euros.
- Optimista: los beneficios anuales superan los 5 millones de euros desde el año 3, llegando hasta los 5,6 millones de euros interanuales en los últimos periodos analizado. El beneficio acumulado es el que presenta la evolución más rápida: alcanza el umbral positivo en el año 9 (media de 3,11 millones de euros) y continúa creciendo con fuerza hasta cerrar el año 20 con un beneficio acumulado medio de 63,64 millones de euros y un rango entre 47,99 y 79,87 millones de euros. Este escenario refleja el máximo potencial financiero del modelo SilverHub, destacando la importancia de maximizar tanto la tasa de ocupación como la conversión al plan premium.

Figura 26. Simulación de beneficios interanuales

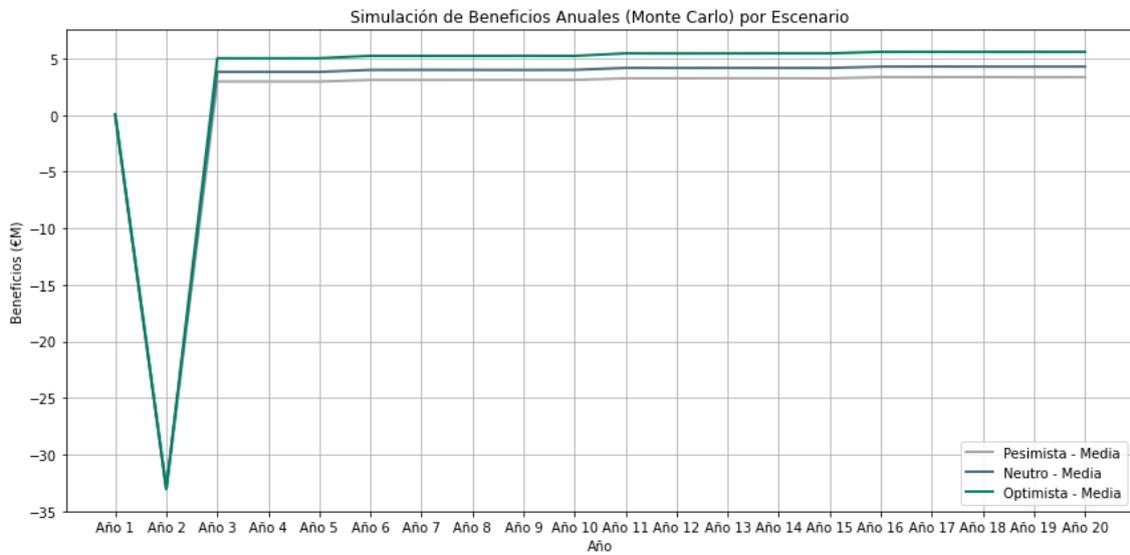
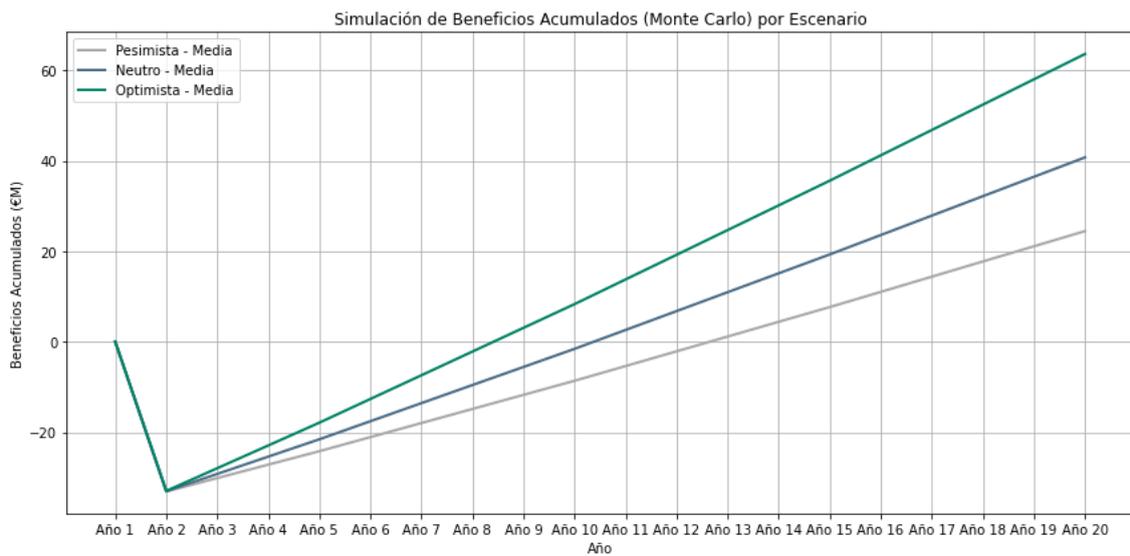


Figura 27. Simulación de beneficios acumulados



Los resultados obtenidos mediante la simulación Monte Carlo confirman la viabilidad económica del modelo SilverHub en los tres escenarios analizados (pesimista, neutro y optimista), aunque con diferencias significativas en cuanto a los plazos de recuperación de la inversión y los márgenes de rentabilidad alcanzados.

El punto de equilibrio financiero, entendido como el momento en que los beneficios acumulados igualan a los costes totales, se alcanza en el año 14 bajo el escenario pesimista, en el año 11 en el neutro, y en el año 9 en el optimista. Esta variabilidad permite adaptar las expectativas de retorno en función del contexto comercial y operativo en el

que se desarrolle el proyecto.

En términos de beneficios acumulados al finalizar el horizonte temporal de análisis (año 20), el modelo presenta una horquilla que oscila entre 24 millones y 64 millones de euros, dependiendo del escenario. Esta diferencia de más de 40 millones de euros evidencia la alta sensibilidad del modelo ante factores clave como la tasa de ocupación y la evolución en la adopción del plan premium.

Asimismo, la transición progresiva hacia el plan premium juega un papel esencial en la mejora de la rentabilidad del proyecto. Esta estrategia permite aumentar los ingresos por residente a lo largo del tiempo sin que ello suponga un incremento proporcional de los costes, gracias a las economías de escala derivadas de los servicios comunitarios.

Por último, en todos los escenarios, las pérdidas iniciales asociadas a la fase de inversión son compensadas con los beneficios generados en los años posteriores. Esto subraya la importancia de implementar una estrategia comercial efectiva desde los primeros años y de optimizar la estructura de costes operativos, garantizando así la sostenibilidad y rentabilidad a largo plazo del modelo SilverHub.

6. Consideraciones finales

En este trabajo se ha llevado a cabo un análisis exhaustivo que permite confirmar la viabilidad económica, social y estratégica del modelo SilverHub, un complejo residencial prefabricado enfocado a personas mayores autónomas que buscan mantener su independencia, evitar la soledad y tener acceso a servicios especializados.

En primer lugar, mediante el análisis PESTEL, se ha logrado identificar claramente oportunidades significativas derivadas del envejecimiento poblacional acelerado en España, como la creciente demanda de alternativas residenciales frente a la oferta tradicional de residencias geriátricas. Esta tendencia, combinada con factores sociales como el aumento de la esperanza de vida, el deseo generalizado de mantener la autonomía el mayor tiempo posible, y la creciente capacidad de pago gracias a la propiedad inmobiliaria generalizada, sustenta la existencia de un mercado amplio y en expansión para SilverHub.

En segundo lugar, la aplicación del modelo de las Cinco Fuerzas de Porter ha demostrado

que, aunque existe una rivalidad intensa en el mercado del "*senior living*", la propuesta de SilverHub se diferencia suficientemente mediante la promoción de la autonomía, la calidad en servicios complementarios y la flexibilidad del alquiler mensual. Esto coloca al proyecto en una posición competitiva favorable frente a modelos tradicionales y alternativos como las residencias asistenciales y las cooperativas de "*cohousing*".

Adicionalmente, la utilización de técnicas analíticas avanzadas (Análisis de Componentes Principales y "*clustering*") ha permitido segmentar territorialmente España, identificando con precisión las provincias con mayor potencial para la implantación inicial de SilverHub. Este análisis estratégico culminó con la selección fundamentada de Madrid y Barcelona, basándose en su alta concentración de población mayor, pensiones superiores a la media nacional y capacidad económica suficiente para asegurar la demanda del proyecto.

En términos financieros, la implementación de simulaciones Monte Carlo para evaluar la rentabilidad económica del modelo en los escenarios pesimista, neutro y optimista ha proporcionado resultados sólidos y robustos. La simulación demostró claramente la viabilidad económica del proyecto, alcanzando el punto de equilibrio entre los años 9 (optimista) y 14 (pesimista). Además, los beneficios acumulados previstos varían significativamente según el escenario, reflejando claramente la sensibilidad del modelo a factores clave como la tasa de ocupación y la proporción de residentes en el plan premium, con beneficios acumulados estimados entre 24 y 64 millones de euros al cabo de 20 años.

Finalmente, a partir de los análisis realizados se han establecido recomendaciones estratégicas clave para asegurar el éxito sostenible del proyecto. Entre estas destacan la necesidad de una estrategia comercial agresiva desde la fase inicial para maximizar las tasas de ocupación, especialmente en los primeros años de operación, así como una adecuada transición hacia servicios premium conforme envejecen los residentes, optimizando así los ingresos sin elevar significativamente los costes operativos.

Anexos

Anexo I. Código R para el análisis exploratorio y reducción de la dimensionalidad (PCA)

```
library(readxl)
library(corrplot)
library(RColorBrewer)
library(ggplot2)
library(reshape2)
library(factoextra)
library(NbClust)
library(dplyr)
library(cluster)
library(fastDummies)
library(ggcorrplot)

rm(list = ls())
(dirname(rstudioapi::getActiveDocumentContext()$path))
getwd()

data <- read_excel("Dataset provincias.xlsx")
data_numeric <- data[, -1] # Excluimos la columna de nombres

# 1. PCA: Reducción de dimensionalidad (escalando los datos)
pca_result <- prcomp(data_numeric, center = TRUE, scale. = TRUE)

# 2. Calcular la varianza explicada por cada componente
var_explained <- (pca_result$sdev^2) / sum(pca_result$sdev^2) * 100
cum_var <- cumsum(var_explained)

# 2. Crear un dataframe para la gráfica
df_variance <- data.frame(
  Componente = factor(1:length(var_explained)),
  VarianzaExplicada = var_explained,
  VarianzaAcumulada = cum_var
)

# 2. Gráfico de varianza explicada y acumulada
ggplot(df_variance, aes(x = Componente)) +
  geom_bar(aes(y = VarianzaExplicada, fill = "Varianza Explicada"),
    stat = "identity", width = 0.7) +
  geom_line(aes(y = VarianzaAcumulada, color = "Varianza
Acumulada", group = 1),
    size = 1.5) +
  geom_point(aes(y = VarianzaAcumulada, color = "Varianza
Acumulada"),
```

```

        size = 3) +
geom_text(aes(y = VarianzaAcumulada,
              label = paste0(round(VarianzaAcumulada, 1), "%")),
          vjust = -0.8,
          color = "black",
          size = 4) +
scale_y_continuous(limits = c(0, 110), expand = c(0, 0)) +
coord_cartesian(clip = "off") +
scale_fill_manual(name = "", values = c("Varianza Explicada" =
"#A9A9A9")) +
scale_color_manual(name = "", values = c("Varianza Acumulada" =
"#008264")) +
labs(x = "Número de Componentes Principales",
     y = "Varianza explicada (%)",
     title = "Varianza explicada y acumulada por Componente
Principal") +
theme_minimal(base_size = 14) +
theme(
  legend.position = "bottom",
  plot.margin = unit(c(1, 1, 1, 1), "cm") # Márgenes más amplios
)

# 3. biplot

fviz_pca_biplot(
  pca_result,
  repel = TRUE, # Evita la superposición de etiquetas
  col.var = "contrib", # Colorea las variables según su
contribución
  gradient.cols = c("#A9A9A9", "#70AD47", "#008264"), # Tres
grados de color
  col.ind = NA, # No se muestran los individuos
  title = "Biplot del PCA",
  xlab = "Componente Principal 1",
  ylab = "Componente Principal 2"
) +
  theme(plot.title = element_text(hjust = 0.5))

```

Anexo II. Código R para determinar el número de “clusters”

```

##DETERMINAR EL NÚMERO ÓPTIMO DE CLUSTERS (Elbow y Silhoutte)##
# 4. se hace un dataframe con los resultados del PCA

pca_datos <- as.data.frame(pca_result$x[, 1:4])

#5. Método Elbow
set.seed(123)

```

```
fviz_nbclust(pca_datos, kmeans, method = "wss", nstart=10,
linecolor = "#008264" ) +
  labs(title = "Método del Codo") +
  theme(plot.title = element_text(hjust = 0.5))
```

```
# 6. Método de la Silueta
fviz_nbclust(pca_datos, kmeans, method = "silhouette",
nstart=10, linecolor = "#008264") +
  labs(title = "Método de la Silueta")+
  theme(plot.title = element_text(hjust = 0.5))
```

Anexo III. Código R para el “*clustering*” jerárquico

```
# 7. Clustering jerárquico: Dendrograma usando distancia euclidia y
enlace Ward
d_euc <- dist(pca_datos, method = "euclidean")
hc_euc <- hclust(d_euc, method = "ward.D2")
plot(hc_euc, hang = -1, main = "Dendrograma con distancia Euclidia
y Ward")
# 7. Se establece k=3 en el dendrograma
fviz_dend(hc_euc, k = 3, k_colors = c("#008264",
"#4C6D87", "#C0392B"), main = "Dendrograma - Euclídea - Método Ward
", xlab="Índices de las observaciones", ylab="Distancia")+
  theme(plot.title = element_text(hjust = 0.5))
# 7. Asignar clusters a cada observación (por ejemplo, 3 clusters)
clusters_euc <- cutree(hc_euc, k = 3)
# 7. Crear pca_data con clusters jerárquicos para graficar en 2D
pca_data_ward_euc <- data.frame(
  PC1 = pca_result$x[, 1],
  PC2 = pca_result$x[, 2],
  cluster_ward_euc = as.factor(clusters_euc)
)
# 7. Graficar resultados del clustering jerárquico en las 2
primeras comp. principales
ggplot(data = pca_data_ward_euc, aes(x = PC1, y = PC2, color =
cluster_ward_euc)) +
  geom_point(size = 3) +
  labs(
    title = "Clustering Jerárquico - Euclídea - Ward",
    x = "Componente Principal 1",
    y = "Componente Principal 2"
  ) +
  scale_color_manual(values = c("#008264", "#4C6D87", "#C0392B")) +
  theme_bw()
# 7. Gráfico de Silhouette para evaluar la calidad del clustering
jerarquico con distancia Euclídea
```

```

silhouette_jer_euc <- silhouette(clusters_euc, dist(pca_datos))
fviz_silhouette(silhouette_jer_euc,,palette = c("#008264",
"#4C6D87", "#C0392B"))

```

```

# 7. Observaciones mal asignadas
silhouette_jer_euc[silhouette_jer_euc[, "sil_width"] < 0,]
which(silhouette_jer_euc[, "sil_width"] < 0)

```

Anexo IV. Código R para el “clustering” con k-means

```

# 11. Hacer clustering con k=4
set.seed(123)
km4 <- kmeans(pca_datos, centers = 4, nstart = 10)
# 11. Crear el dataframe para visualizar los datos en 2D
pca_data_km4 <- data.frame(
  PC1 = pca_result$x[, 1],
  PC2 = pca_result$x[, 2],
  cluster = as.factor(km4$cluster)
)

# 11. Graficar clustering k-means con 4 clusters
ggplot(pca_data_km4, aes(x = PC1, y = PC2, color = cluster)) +
  geom_point(size = 3) +
  labs(title = "Clustering K-means: 4 clusters",
       x = "Componente Principal 1",
       y = "Componente Principal 2") +
  scale_color_manual(values = c("#008264", "#4C6D87", "#C0392B",
"#D9CBA3")) +
  theme_minimal()

# 11. Gráfico de Silhouette para evaluar la calidad del clustering
para k=4
silhouette_km4 <- silhouette(km4$cluster, dist(pca_datos))
fviz_silhouette(silhouette_km4, palette = c("#008264",
"#4C6D87", "#C0392B", "#D9CBA3"))

# 11. Observaciones mal asignadas
silhouette_km4[silhouette_km4[, "sil_width"] < 0,]
which(silhouette_km4[, "sil_width"] < 0)

```

Anexo V. Código R para la evaluación de perfiles y selección final de la ubicación

```

# Definir las variables que se eliminarán por su alta correlación
cols_eliminar <- c("# pensiones viudedad", "# hogares
unipersonales", "# hogares alquiler",
                  "# hogares pagos pendientes", "# hogares
pagados")

```

```

# Crear un nuevo DataFrame filtrado, eliminando las variables
redundantes
data_numeric_filtrado <- data_numeric %>% select(-
one_of(cols_eliminar))

# 12. Plot de los centroides: Añadimos la asignación de cluster
(km4$cluster) al DataFrame filtrado
df_profiles <- data_numeric_filtrado %>% mutate(cluster =
km4$cluster)

# 12. Calcular las medias de cada variable por cluster
cluster_means <- df_profiles %>%
  group_by(cluster) %>%
  summarise(across(where(is.numeric), mean, na.rm = TRUE))

# 12. Estandarizar los promedios para que todas las variables
tengan media 0 y desviación 1
cluster_means_z <- cluster_means
cluster_means_z[, -1] <- scale(cluster_means_z[, -1])

# 12. Convertir a formato largo para ggplot
df_melt <- melt(cluster_means_z, id.vars = "cluster")

# 12. Graficar el profile plot de los centroides con los colores
especificados
ggplot(df_melt, aes(x = variable, y = value, group =
factor(cluster), color = factor(cluster))) +
  geom_line(size = 1.2) +
  geom_point(size = 2.5) +
  labs(title = "Profile Plot of Centroids (Variables Filtradas)",
        x = "Variables",
        y = "Valor Estandarizado",
        color = "Cluster") +
  scale_color_manual(values = c("#008264", "#4C6D87", "#C0392B",
"#D9CBA3")) +
  theme_minimal() +
  theme(axis.text.x = element_text(angle = 45, hjust = 1))

# 13. Crear la tabla de asignación de clusters
province_cluster <- data.frame(
  Provincia = data[[1]],
  Cluster = km4$cluster
)

# 13. Ordenar la tabla por Cluster
province_cluster <-
province_cluster[order(province_cluster$Cluster), ]

```

```

# Crear la tabla inicial con las provincias y su cluster asignado
province_cluster <- data.frame(
  Provincia = data[[1]],
  Cluster = km4$cluster
)

# Dividir el vector de provincias por cluster
clusters_list <- split(province_cluster$Provincia,
  province_cluster$Cluster)

# Determinar la cantidad máxima de provincias en un cluster
max_len <- max(sapply(clusters_list, length))

# Rellenar cada vector con NA hasta alcanzar 'max_len'
clusters_df <- sapply(clusters_list, function(x) c(x, rep(NA,
  max_len - length(x))))
clusters_df <- as.data.frame(clusters_df)

# Renombrar las columnas para que se muestre "Cluster 1", "Cluster
2", etc.
colnames(clusters_df) <- paste("Cluster", colnames(clusters_df))

# Visualizar la tabla con formato
library(knitr)
kable(clusters_df, caption = "Asignación de Provincias por
Cluster")

```

Anexo VI. Código Python para la simulación de estructura de ingresos

```

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from tabulate import tabulate

# -----
# PARÁMETROS GENERALES
# -----
n_simulaciones = 10000 # Número de simulaciones
n_anios = 20 # Horizonte: 20 años
inicio_operacion = 3 # Los ingresos (por alquiler y
mantenimiento) comienzan en el año 3
n_centros = 2 # Dos complejos: Madrid y Barcelona

# -----
# ESCENARIOS: Tasas de ocupación y reservas
# -----
escenarios = {

```

```

    "Pesimista": {
        "ocup_min": 0.60, "ocup_max": 0.70,
        "reserva_min": 0.25, "reserva_max": 0.50,
        "color": "#A9A9A9"
    },
    "Neutro": {
        "ocup_min": 0.70, "ocup_max": 0.85,
        "reserva_min": 0.50, "reserva_max": 0.75,
        "color": "#4C6D87"
    },
    "Optimista": {
        "ocup_min": 0.90, "ocup_max": 1.00,
        "reserva_min": 0.75, "reserva_max": 0.90,
        "color": "#008264"
    }
}

# -----
# PARÁMETROS DE OPERACIÓN (fijos para todos los escenarios)
# -----
# Rango de precios mensuales de alquiler para cada plan:
precio_basico_range = (2000, 2400) # €/mes
precio_premium_range = (2600, 2800) # €/mes

# Depósitos de reserva (pago único)
dep_basico = 500 # €/unidad
dep_premium = 600 # €/unidad
# Proporción de adopción en reserva (se asume mayor adopción del
plan básico)
prop_reserva_basico = 0.80
prop_reserva_premium = 0.20

# Tasa de mantenimiento mensual (cuota que abona cada residente)
mantenimiento_range = (100, 150) # €/mes

# Función que define la evolución del plan mix a lo largo de los
años operativos
def plan_mix(año):
    # Devuelve una tupla (prop_basico, prop_premium) para cada año
de operación (años >=3)
    if año < inicio_operacion or año > n_años:
        return (0, 0)
    elif 3 <= año <= 5:
        return (0.80, 0.20)
    elif 6 <= año <= 10:
        return (0.65, 0.35)
    elif 11 <= año <= 15:
        return (0.50, 0.50)
    elif 16 <= año <= 20:

```

```

        return (0.40, 0.60)

# Número de viviendas por centro: se simula un valor uniforme entre
100 y 150.
def simular_viviendas_por_centro():
    return np.random.uniform(100, 150)

# -----
# FUNCIÓN DE SIMULACIÓN DE INGRESOS
# -----
def simular_ingresos(escenario):
    # Extraemos los parámetros del escenario
    ocup_min = escenario["ocup_min"]
    ocup_max = escenario["ocup_max"]
    reserva_min = escenario["reserva_min"]
    reserva_max = escenario["reserva_max"]

    # Número total de viviendas para ambos centros
    n_viviendas_por_centro = simular_viviendas_por_centro()
    n_viviendas_totales = n_viviendas_por_centro * n_centros

    ingresos = []
    # Se simulan ingresos para cada año del horizonte
    for año in range(1, n_años + 1):
        if año <= 2:
            # Años 1 y 2: solo ingresos por reservas (fase de
            construcción y trámites)
            reserva_rate = np.random.uniform(reserva_min,
            reserva_max)
            n_reservas = n_viviendas_totales * reserva_rate
            ingreso_reserva = n_reservas * (prop_reserva_basico *
            dep_basico + prop_reserva_premium * dep_premium)
            ingresos.append(ingreso_reserva)
        else:
            # Años de operación (a partir del año 3): ingresos por
            alquiler y mantenimiento
            ocupacion = np.random.uniform(ocup_min, ocup_max)
            prop_basico, prop_premium = plan_mix(año)
            # Simular precios mensuales del alquiler para cada plan
            (dentro de su rango)
            precio_basico = np.random.uniform(*precio_basico_range)
            precio_premium =
            np.random.uniform(*precio_premium_range)
            # Precio medio ponderado del alquiler mensual
            alquiler_mensual = precio_basico * prop_basico +
            precio_premium * prop_premium
            ingreso_mensual = alquiler_mensual *
            n_viviendas_totales * ocupacion
            ingreso_alquiler_anual = ingreso_mensual * 12

```

```

        # Ingresos anuales por mantenimiento
        cuota_mantenimiento =
np.random.uniform(*mantenimiento_range)
        ingreso_mantenimiento_anual = cuota_mantenimiento *
n_viviendas_totales * 12

        ingresos.append(ingreso_alquiler_anual +
ingreso_mantenimiento_anual)
        return ingresos

# -----
# SIMULACIÓN PARA CADA ESCENARIO
# -----
resultados = {}
for nombre, config in escenarios.items():
    simulaciones = [simular_ingresos(config) for _ in
range(n_simulaciones)]
    df_simulaciones = pd.DataFrame(simulaciones, columns=[f"Año
{i}" for i in range(1, n_años+1)])
    resultados[nombre] = {
        'mean': df_simulaciones.mean(),
        'median': df_simulaciones.median(),
        'p5': df_simulaciones.quantile(0.05),
        'p95': df_simulaciones.quantile(0.95),
        'color': config["color"]
    }

# -----
# GRÁFICO COMPARATIVO DE INGRESOS
# -----
plt.figure(figsize=(12, 6))
for nombre, stats in resultados.items():
    plt.plot(stats['mean'] / 1e6, label=f"{nombre} - Media",
linewidth=2, color=stats['color'])
plt.title("Simulación de Ingresos Anuales por Escenario - Monte
Carlo")
plt.xlabel("Año")
plt.ylabel("Ingresos (€M)")
plt.legend()
plt.grid(True)
plt.xticks(range(n_años), labels=[f"Año {i}" for i in range(1,
n_años+1)])
plt.tight_layout()
plt.show()

# -----
# TABLA DE ESTADÍSTICAS PARA TODOS LOS ESCENARIOS
# -----

```

```

from tabulate import tabulate

# Para cada escenario, crear y mostrar la tabla con formato
"fancy_grid"
for nombre, stats in resultados.items():
    # Crear un DataFrame con los valores en millones y 2 decimales
    df_stats = pd.DataFrame({
        "Año": [f"Año {i}" for i in range(1, n_años+1)],
        "Media (€M)": stats['mean'].values / 1_000_000,
        "Mediana (€M)": stats['median'].values / 1_000_000,
        "P5 (€M)": stats['p5'].values / 1_000_000,
        "P95 (€M)": stats['p95'].values / 1_000_000
    })

    # Convertir el DataFrame en una lista de listas para usar
    tabulate
    data_tabulate = df_stats.values.tolist()
    headers = df_stats.columns.tolist()

    # Generar y mostrar la tabla con estilo 'fancy_grid' y dos
    decimales
    table_str = tabulate(data_tabulate, headers=headers,
        tablefmt='fancy_grid', floatfmt=".2f")
    print(f"\nEstadísticas de ingresos para el escenario
    '{nombre}':\n")
    print(table_str)

# SIMULACIÓN PARA CADA ESCENARIO Y ACUMULADOS
# -----
resultados_acum = {}
for nombre, config in escenarios.items():
    # Simula ingresos anuales para cada simulación
    simulaciones = [simular_ingresos(config) for _ in
    range(n_simulaciones)]
    df_simulaciones = pd.DataFrame(simulaciones, columns=[f"Año
    {i}" for i in range(1, n_años+1)])
    # Calcular la suma acumulada de ingresos a lo largo de los años
    df_acum = df_simulaciones.cumsum(axis=1)
    resultados_acum[nombre] = {
        'mean': df_acum.mean(),
        'median': df_acum.median(),
        'p5': df_acum.quantile(0.05),
        'p95': df_acum.quantile(0.95),
        'color': config["color"]
    }
}

```

```

# -----
# GRÁFICO COMPARATIVO DE INGRESOS ACUMULADOS
# -----
plt.figure(figsize=(12, 6))
for nombre, stats in resultados_acum.items():
    plt.plot(stats['mean'] / 1e6, label=f"{nombre} - Media",
linewith=2, color=stats['color'])
plt.title("Simulación de Ingresos Acumulados Anuales (Monte
Carlo)")
plt.xlabel("Año")
plt.ylabel("Ingresos Acumulados (€M)")
plt.legend()
plt.grid(True)
plt.xticks(range(n_años), labels=[f"Año {i}" for i in range(1,
n_años+1)])
plt.tight_layout()
plt.show()

# -----
# TABLA DE ESTADÍSTICAS DE INGRESOS ACUMULADOS POR ESCENARIO (con
formato)
# -----
print("Estadísticas de Ingresos Acumulados (Monte Carlo):")
for nombre, stats in resultados_acum.items():
    df_resumen = pd.DataFrame({
        "Año": [f"Año {i}" for i in range(1, n_años+1)],
        "Media (€M)": stats['mean'].values / 1_000_000,
        "Mediana (€M)": stats['median'].values / 1_000_000,
        "P5 (€M)": stats['p5'].values / 1_000_000,
        "P95 (€M)": stats['p95'].values / 1_000_000
    })
    table_str = tabulate(df_resumen, headers="keys",
tablefmt="fancy_grid", floatfmt=".2f")
    print(f"\nEstadísticas de Ingresos Acumulados para el escenario
'{nombre}':\n")
    print(table_str)

```

Anexo VII. Código Python para la simulación de estructura de costes

```

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from tabulate import tabulate
# -----
# PARÁMETROS GENERALES
# -----

```

```

n_simulaciones = 10000 # Número de simulaciones
n_anios = 20 # Horizonte: 20 años
n_preop = 2 # Período preoperativo: Año 1 y Año 2
n_centros = 2 # Dos complejos: Madrid y Barcelona

# -----
# COSTES UPFRONT (Pagos únicos en el período preoperativo)
# -----

# Terreno:
def simular_area():
    # Área necesaria por complejo: uniforme entre 15,000 y 20,000
    m2
    return np.random.uniform(15000, 20000)

# Coste del terreno en €/m2:
coste_terreno_madrid = 306.7
coste_terreno_barcelona = 204.2

def calcular_coste_terreno():
    area_madrid = simular_area()
    area_barcelona = simular_area()
    coste_madrid = area_madrid * coste_terreno_madrid
    coste_barcelona = area_barcelona * coste_terreno_barcelona
    return coste_madrid + coste_barcelona

# Casas prefabricadas:
area_casa = 49 # m2 por vivienda
def simular_numero_viviendas():
    # Número de viviendas por complejo: uniforme entre 100 y 150
    viviendas1 = np.random.uniform(100, 150)
    viviendas2 = np.random.uniform(100, 150)
    return viviendas1, viviendas2

def calcular_coste_casas():
    viviendas1, viviendas2 = simular_numero_viviendas()
    # Coste por m2: uniforme entre 1,200 y 2,500 €
    coste_m2_1 = np.random.uniform(1200, 2500)
    coste_m2_2 = np.random.uniform(1200, 2500)
    coste_1 = viviendas1 * area_casa * coste_m2_1
    coste_2 = viviendas2 * area_casa * coste_m2_2
    return coste_1 + coste_2

# Servicios comunitarios:
def calcular_coste_servicios():
    # Cada complejo: uniforme entre 550,000 y 940,000 €
    servicios1 = np.random.uniform(550000, 940000)
    servicios2 = np.random.uniform(550000, 940000)
    return servicios1 + servicios2

```

```

# Licencias y tasas (pago único para ambos complejos):
def calcular_coste_licencias():
    return np.random.uniform(40000, 60000)

# Función para obtener los costes upfront
def simular_costes_upfront():
    terreno = calcular_coste_terreno()
    casas = calcular_coste_casas()
    servicios = calcular_coste_servicios()
    licencias = calcular_coste_licencias()
    return terreno, casas, servicios, licencias

# -----
# COSTES OPERATIVOS (Años 3 a 20)
# -----
def simular_gasto_personal():
    # Gasto de personal por complejo: uniforme entre 1,000,000 y
    1,500,000 €
    personal1 = np.random.uniform(325000, 450000)
    personal2 = np.random.uniform(325000, 450000)
    return personal1 + personal2

def simular_otros_gastos():
    # Otros gastos operativos por complejo: uniforme entre 500,000
    y 600,000 €
    otros1 = np.random.uniform(160000, 220000)
    otros2 = np.random.uniform(220000, 220000)
    return otros1 + otros2

def simular_costes_operativos():
    return simular_gasto_personal() + simular_otros_gastos()

# -----
# AMORTIZACIÓN (A partir del año 3, se amortiza la inversión del
año 2)
# -----
def calcular_amortizacion(costo_capitalizado):
    # Se asume una vida útil aleatoria entre 40 y 50 años
    vida_util = np.random.uniform(40, 50)
    return costo_capitalizado / vida_util

# -----
# SIMULACIÓN DE COSTES TOTALES (20 AÑOS)
# -----
def simular_costes_totales():
    costes = []
    # Simular los costes upfront (año 1 y año 2)

```

```

    coste_terreno, coste_casas, coste_servicios, coste_lic =
simular_costes_upfront()

    # Año 1: Se pagan las licencias y tasas (pago único)
    coste_año1 = coste_lic
    costes.append(coste_año1)

    # Año 2: Se pagan los costes de terreno, casas y servicios
(capitalizados)
    coste_año2 = coste_terreno + coste_casas + coste_servicios
    costes.append(coste_año2)

    # Calcular la amortización anual de la inversión del año 2
    amortizacion_anual = calcular_amortizacion(coste_año2)

    # Años operativos (año 3 a 20): se pagan costes operativos +
amortización anual
    for _ in range(n_anios - n_preop):
        costes_operativos = simular_costes_operativos()
        costes.append(costes_operativos + amortizacion_anual)
    return costes

# Ejecutar la simulación Monte Carlo para los costes
simulaciones_costes = [simular_costes_totales() for _ in
range(n_simulaciones)]
df_costes = pd.DataFrame(simulaciones_costes, columns=[f"Año {i}"
for i in range(1, n_anios+1)])

# Calcular estadísticas por año
costes_mean = df_costes.mean()
costes_median = df_costes.median()
costes_p5 = df_costes.quantile(0.05)
costes_p95 = df_costes.quantile(0.95)

# -----
# GRÁFICO COMPARATIVO DE COSTES ANUALES (SIMULACIÓN MONTE CARLO) -
Eje Y en millones
# -----
plt.figure(figsize=(12, 6))
plt.plot(costes_mean / 1e6, label="Media de Costes",
color="#008264", linewidth=2)
plt.plot(costes_median / 1e6, label="Mediana de Costes",
color="#4C6D87", linestyle="--")
plt.fill_between(range(n_anios), costes_p5 / 1e6, costes_p95 / 1e6,
alpha=0.2, color="#C0392B", label="Intervalo 90%")
plt.title("Simulación de Costes Anuales (Monte Carlo)")
plt.xlabel("Año")
plt.ylabel("Costes (€M)")
plt.legend()

```

```

plt.grid(True)
plt.xticks(range(n_años), labels=[f"Año {i}" for i in range(1,
n_años+1)])
plt.tight_layout()
plt.show()

# Crear un DataFrame consolidado con las estadísticas de costes
para todos los años
df_costes_resumen = pd.DataFrame({
    "Año": [f"Año {i}" for i in range(1, n_años+1)],
    "Media (€M)": costes_mean.values / 1_000_000,
    "Mediana (€M)": costes_median.values / 1_000_000,
    "P5 (€M)": costes_p5.values / 1_000_000,
    "P95 (€M)": costes_p95.values / 1_000_000
})

# Mostrar la tabla consolidada usando tabulate
table_str = tabulate(df_costes_resumen, headers="keys",
tablefmt="fancy_grid", floatfmt=".2f")
print(table_str)

# -----
# CALCULO DE COSTES ACUMULADOS
# -----
# Se calcula la suma acumulada de los costes a lo largo de los años
df_costes_acum = df_costes.cumsum(axis=1)

# Calcular estadísticas para los costes acumulados:
costes_acum_mean = df_costes_acum.mean()
costes_acum_median = df_costes_acum.median()
costes_acum_p5 = df_costes_acum.quantile(0.05)
costes_acum_p95 = df_costes_acum.quantile(0.95)

# -----
# GRÁFICO COMPARATIVO DE COSTES ACUMULADOS (Monte Carlo)
# -----
plt.figure(figsize=(12, 6))
plt.plot(costes_acum_mean / 1e6, label="Media de Costes
Acumulados", color="#008264", linewidth=2)
plt.plot(costes_acum_median / 1e6, label="Mediana de Costes
Acumulados", color="#4C6D87", linestyle="--")
plt.fill_between(range(n_años), costes_acum_p5 / 1e6,
costes_acum_p95 / 1e6,
                alpha=0.2, color="#C0392B", label="Intervalo 90%")
plt.title("Simulación de Costes Acumulados Anuales (Monte Carlo)")
plt.xlabel("Año")
plt.ylabel("Costes Acumulados (€M)")
plt.legend()

```

```

plt.grid(True)
plt.xticks(range(n_anios), labels=[f"Año {i}" for i in range(1,
n_anios+1)])
plt.tight_layout()
plt.show()

# -----
# TABLA DE ESTADÍSTICAS DE COSTES ACUMULADOS (Formato ejecutivo)
# -----
df_resumen_costes = pd.DataFrame({
    "Año": [f"Año {i}" for i in range(1, n_anios+1)],
    "Media (€M)": costes_acum_mean.values / 1e6,
    "Mediana (€M)": costes_acum_median.values / 1e6,
    "P5 (€M)": costes_acum_p5.values / 1e6,
    "P95 (€M)": costes_acum_p95.values / 1e6
})
table_str = tabulate(df_resumen_costes, headers="keys",
tablefmt="fancy_grid", floatfmt=".2f")
print(table_str)

```

Anexo VIII. Código Python para la simulación del beneficio

```

import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from tabulate import tabulate

# -----
# -----
# CALCULAR BENEFICIOS ANUALES (INGRESOS - COSTES) PARA CADA
# ESCENARIO
# -----
# -----
beneficios_resultados = {}
for nombre in escenarios.keys():
    beneficios_resultados[nombre] = {
        'mean': resultados[nombre]['mean'] - costes_mean,
        'median': resultados[nombre]['median'] - costes_median,
        'p5': resultados[nombre]['p5'] - costes_p5,
        'p95': resultados[nombre]['p95'] - costes_p95,
        'color': escenarios[nombre]['color']
    }

# -----
# -----
# GRÁFICO COMPARATIVO DE BENEFICIOS ANUALES (No acumulados) -
# Valores en millones

```

```

# -----
-----
plt.figure(figsize=(12, 6))
for nombre, stats in beneficios_resultados.items():
    plt.plot(stats['mean'] / 1e6, label=f"{nombre} - Media",
linewidth=2, color=stats['color'])
plt.title("Simulación de Beneficios Anuales (Monte Carlo) por
Escenario")
plt.xlabel("Año")
plt.ylabel("Beneficios (€M)")
plt.legend()
plt.grid(True)
plt.xticks(range(n_anios), labels=[f"Año {i}" for i in range(1,
n_anios+1)])
plt.tight_layout()
plt.show()

# -----
-----
# TABLA DE ESTADÍSTICAS DE BENEFICIOS ANUALES PARA CADA ESCENARIO
(con formato)
# -----
-----
for nombre, stats in beneficios_resultados.items():
    df_benef = pd.DataFrame({
        "Año": [f"Año {i}" for i in range(1, n_anios+1)],
        "Media (€M)": stats['mean'].values / 1_000_000,
        "Mediana (€M)": stats['median'].values / 1_000_000,
        "P5 (€M)": stats['p5'].values / 1_000_000,
        "P95 (€M)": stats['p95'].values / 1_000_000
    })
    table_str = tabulate(df_benef, headers="keys",
tablefmt="fancy_grid", floatfmt=".2f")
    print(f"\nEstadísticas de Beneficios Anuales para el escenario
'{nombre}':\n")
    print(table_str)

# -----
-----
# CÁLCULO DE BENEFICIOS ACUMULADOS PARA CADA ESCENARIO
# -----
-----
beneficios_acumulados = {}
for nombre, stats in beneficios_resultados.items():
    beneficios_acumulados[nombre] = {
        'mean': stats['mean'].cumsum(),
        'median': stats['median'].cumsum(),
        'p5': stats['p5'].cumsum(),
        'p95': stats['p95'].cumsum(),

```

```

        'color': stats['color']
    }

# -----
# GRÁFICO COMPARATIVO DE BENEFICIOS ACUMULADOS - Valores en
# millones de euros
# -----

plt.figure(figsize=(12, 6))
for nombre, stats in beneficios_acumulados.items():
    plt.plot(stats['mean'] / 1e6, label=f"{nombre} - Media",
             linewidth=2, color=stats['color'])
plt.title("Simulación de Beneficios Acumulados (Monte Carlo) por
Escenario")
plt.xlabel("Año")
plt.ylabel("Beneficios Acumulados (€M)")
plt.legend()
plt.grid(True)
plt.xticks(range(n_anios), labels=[f"Año {i}" for i in range(1,
n_anios+1)])
plt.tight_layout()
plt.show()

# -----
# TABLAS DE ESTADÍSTICAS DE BENEFICIOS ACUMULADOS PARA CADA
# ESCENARIO (con formato)
# -----

for nombre, stats in beneficios_acumulados.items():
    df_acum = pd.DataFrame({
        "Año": [f"Año {i}" for i in range(1, n_anios+1)],
        "Media (€M)": stats['mean'].values / 1_000_000,
        "Mediana (€M)": stats['median'].values / 1_000_000,
        "P5 (€M)": stats['p5'].values / 1_000_000,
        "P95 (€M)": stats['p95'].values / 1_000_000
    })
    table_str = tabulate(df_acum, headers="keys",
                        tablefmt="fancy_grid", floatfmt=".2f")
    print(f"\nEstadísticas de Beneficios Acumulados para el
escenario '{nombre}':\n")
    print(table_str)

```

Anexo IX. Estadísticas y evolución de la simulación de la estructura financiera

Estadísticas de Ingresos Acumulados para el escenario 'Pesimista':

	Año	Media (€M)	Mediana (€M)	P5 (€M)	P95 (€M)
0	Año 1	0.05	0.05	0.03	0.07
1	Año 2	0.10	0.10	0.07	0.13
2	Año 3	4.95	4.94	3.96	6.01
3	Año 4	9.81	9.81	7.94	11.73
4	Año 5	14.68	14.69	11.94	17.50
5	Año 6	19.68	19.67	16.03	23.36
6	Año 7	24.69	24.67	20.15	29.28
7	Año 8	29.70	29.68	24.27	35.19
8	Año 9	34.71	34.69	28.41	41.10
9	Año 10	39.72	39.73	32.51	47.00
10	Año 11	44.88	44.86	36.76	53.06
11	Año 12	50.04	50.06	41.01	59.11
12	Año 13	55.20	55.16	45.23	65.21
13	Año 14	60.36	60.33	49.45	71.26
14	Año 15	65.51	65.54	53.70	77.37
15	Año 16	70.77	70.76	57.98	83.57
16	Año 17	76.02	75.99	62.31	89.73
17	Año 18	81.28	81.31	66.67	95.97
18	Año 19	86.53	86.55	71.00	102.11
19	Año 20	91.78	91.84	75.26	108.37

Estadísticas de Ingresos Acumulados para el escenario 'Neutro':

	Año	Media (€M)	Mediana (€M)	P5 (€M)	P95 (€M)
0	Año 1	0.08	0.08	0.06	0.10
1	Año 2	0.16	0.16	0.13	0.20
2	Año 3	5.89	5.86	4.67	7.19
3	Año 4	11.60	11.57	9.37	13.95
4	Año 5	17.33	17.28	14.08	20.70
5	Año 6	23.23	23.20	18.94	27.63
6	Año 7	29.12	29.07	23.79	34.56
7	Año 8	35.03	34.98	28.63	41.56
8	Año 9	40.93	40.87	33.47	48.47
9	Año 10	46.82	46.74	38.28	55.43
10	Año 11	52.90	52.78	43.25	62.57
11	Año 12	58.98	58.87	48.29	69.71
12	Año 13	65.04	64.95	53.25	76.86
13	Año 14	71.12	71.00	58.23	84.04
14	Año 15	77.19	77.08	63.21	91.18
15	Año 16	83.38	83.22	68.31	98.49
16	Año 17	89.57	89.46	73.41	105.82
17	Año 18	95.76	95.66	78.52	113.12
18	Año 19	101.95	101.86	83.55	120.42
19	Año 20	108.14	108.02	88.66	127.69

Estadísticas de Ingresos Acumulados para el escenario 'Optimista':

	Año	Media (€M)	Mediana (€M)	P5 (€M)	P95 (€M)
0	Año 1	0.11	0.11	0.09	0.13
1	Año 2	0.21	0.21	0.17	0.26
2	Año 3	7.13	7.10	5.75	8.60
3	Año 4	14.05	14.04	11.44	16.76
4	Año 5	20.98	20.97	17.11	24.92
5	Año 6	28.11	28.15	22.99	33.34
6	Año 7	35.24	35.27	28.84	41.74
7	Año 8	42.38	42.39	34.70	50.15
8	Año 9	49.51	49.56	40.54	58.53
9	Año 10	56.65	56.70	46.41	66.93
10	Año 11	63.99	64.08	52.45	75.55
11	Año 12	71.35	71.45	58.49	84.26
12	Año 13	78.69	78.79	64.50	92.95
13	Año 14	86.04	86.19	70.50	101.55
14	Año 15	93.39	93.52	76.51	110.23
15	Año 16	100.88	101.01	82.67	119.05
16	Año 17	108.37	108.50	88.83	127.98
17	Año 18	115.86	115.99	94.95	136.79
18	Año 19	123.35	123.43	101.09	145.59
19	Año 20	130.84	130.99	107.21	154.48

Estadísticas de costes acumulados:

	Año	Media (€M)	Mediana (€M)	P5 (€M)	P95 (€M)
0	Año 1	0.05	0.05	0.04	0.06
1	Año 2	33.17	33.09	27.17	39.61
2	Año 3	35.06	34.99	28.92	41.67
3	Año 4	36.96	36.89	30.69	43.72
4	Año 5	38.85	38.78	32.45	45.76
5	Año 6	40.74	40.67	34.19	47.82
6	Año 7	42.64	42.57	35.96	49.88
7	Año 8	44.53	44.46	37.71	51.89
8	Año 9	46.42	46.35	39.46	53.97
9	Año 10	48.32	48.25	41.21	56.01
10	Año 11	50.21	50.13	42.95	58.05
11	Año 12	52.11	52.03	44.72	60.07
12	Año 13	54.00	53.92	46.47	62.11
13	Año 14	55.89	55.80	48.23	64.17
14	Año 15	57.79	57.68	49.99	66.20
15	Año 16	59.68	59.57	51.72	68.25
16	Año 17	61.57	61.46	53.46	70.30
17	Año 18	63.47	63.35	55.22	72.34
18	Año 19	65.36	65.25	56.97	74.42
19	Año 20	67.26	67.13	58.69	76.49

Estadísticas de Beneficios Acumulados para el escenario 'Pesimista':

	Año	Media (€M)	Mediana (€M)	P5 (€M)	P95 (€M)
0	Año 1	-0.00	-0.00	-0.01	0.01
1	Año 2	-33.07	-32.99	-27.10	-39.47
2	Año 3	-30.10	-30.04	-24.93	-35.65
3	Año 4	-27.13	-27.08	-22.75	-31.84
4	Año 5	-24.16	-24.12	-20.57	-28.03
5	Año 6	-21.05	-21.02	-18.27	-24.07
6	Año 7	-17.94	-17.92	-15.96	-20.10
7	Año 8	-14.82	-14.81	-13.66	-16.12
8	Año 9	-11.71	-11.71	-11.34	-12.14
9	Año 10	-8.60	-8.62	-9.04	-8.18
10	Año 11	-5.34	-5.37	-6.61	-4.06
11	Año 12	-2.08	-2.12	-4.18	0.05
12	Año 13	1.18	1.14	-1.75	4.18
13	Año 14	4.44	4.40	0.68	8.33
14	Año 15	7.70	7.65	3.12	12.47
15	Año 16	11.06	11.01	5.64	16.70
16	Año 17	14.41	14.37	8.16	20.94
17	Año 18	17.78	17.72	10.68	25.19
18	Año 19	21.13	21.07	13.19	29.43
19	Año 20	24.49	24.42	15.71	33.65

Estadísticas de Beneficios Acumulados para el escenario 'Neutro':

	Año	Media (€M)	Mediana (€M)	P5 (€M)	P95 (€M)
0	Año 1	0.03	0.03	0.02	0.05
1	Año 2	-33.01	-32.93	-27.04	-39.40
2	Año 3	-29.19	-29.14	-24.23	-34.47
3	Año 4	-25.36	-25.34	-21.42	-29.53
4	Año 5	-21.54	-21.54	-18.59	-24.61
5	Año 6	-17.54	-17.56	-15.62	-19.48
6	Año 7	-13.53	-13.58	-12.62	-14.36
7	Año 8	-9.54	-9.61	-9.65	-9.24
8	Año 9	-5.54	-5.64	-6.67	-4.14
9	Año 10	-1.54	-1.66	-3.67	0.98
10	Año 11	2.64	2.50	-0.54	6.30
11	Año 12	6.81	6.66	2.59	11.63
12	Año 13	10.99	10.81	5.70	16.95
13	Año 14	15.16	14.96	8.83	22.28
14	Año 15	19.33	19.10	11.95	27.60
15	Año 16	23.62	23.35	15.17	33.07
16	Año 17	27.91	27.62	18.40	38.53
17	Año 18	32.20	31.89	21.62	43.98
18	Año 19	36.49	36.15	24.85	49.42
19	Año 20	40.78	40.41	28.07	54.86

Estadísticas de Beneficios Acumulados para el escenario 'Optimista':

	Año	Media (€M)	Mediana (€M)	P5 (€M)	P95 (€M)
0	Año 1	0.06	0.06	0.04	0.07
1	Año 2	-32.96	-32.88	-26.99	-39.35
2	Año 3	-27.92	-27.86	-23.14	-33.10
3	Año 4	-22.89	-22.84	-19.26	-26.81
4	Año 5	-17.86	-17.81	-15.41	-20.53
5	Año 6	-12.62	-12.58	-11.34	-14.04
6	Año 7	-7.38	-7.33	-7.28	-7.54
7	Año 8	-2.14	-2.09	-3.23	-1.06
8	Año 9	3.11	3.15	0.84	5.42
9	Año 10	8.35	8.38	4.89	11.92
10	Año 11	13.81	13.84	9.14	18.64
11	Año 12	19.26	19.28	13.38	25.34
12	Año 13	24.72	24.73	17.63	32.07
13	Año 14	30.18	30.18	21.89	38.80
14	Año 15	35.64	35.63	26.13	45.52
15	Año 16	41.24	41.23	30.52	52.40
16	Año 17	46.84	46.82	34.88	59.27
17	Año 18	52.44	52.42	39.25	66.13
18	Año 19	58.04	58.01	43.63	73.01
19	Año 20	63.64	63.62	47.99	79.87

Anexo X. Declaración de uso de IA

Por la presente, yo, Ignacio García, estudiante de Business Analytics y Relaciones Internacionales de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado " SilverHub: Proyecto de Análisis de Datos para la Evaluación del Sector "Senior Living" en España", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

1. **Brainstorming de ideas de investigación:** Utilizado para idear y esbozar posibles áreas de investigación.
2. **Referencias:** Usado conjuntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.
3. **Metodólogo:** Para descubrir métodos aplicables a problemas específicos de investigación.
4. **Interpretador de código:** Para realizar análisis de datos preliminares.
5. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
6. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
7. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
8. **Traductor:** Para traducir textos de un lenguaje a otro.

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado ChatGPT u otras herramientas similares). Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: 10 de abril del 2025

Firma: Ignacio

Bibliografía

- Alireza, M. (2022). Efficacy of prefabrications on constructions' waste cost and its eco-efficiency. *Civil and Environmental Engineering Reports*, 32(2), 207-227. <https://doi.org/10.2478/ceer-2022-0036>
- Alonso, R. (1 de junio del 2022). 'Cohousing senior': el futuro de las viviendas para personas mayores. *Idealista News*. Recuperado de <https://www.idealista.com/news/inmobiliario/vivienda/2022/06/01/>

[796971-el-futuro-de-las-viviendas-senior-donde-y-como-viviremos-de-mayores](#)

Ayuntamiento de Madrid. (s.f.). Estudio y regulación en Madrid: Cohousing senior. *Portal web del Ayuntamiento de Madrid*. Recuperado el 23 de marzo de 2025, de

Cao, X., Li, X., Zhu, Y., y Zhang, Z. (2015). A comparative study of environmental performance between prefabricated and traditional residential buildings in China. *Journal of Cleaner Production*, 109, 131-143. <https://doi.org/10.1016/j.jclepro.2015.04.136>

Cattan, M., White, M., Bond, J., & Learmouth, A. (2005). Preventing social isolation and loneliness among older people: a systematic review of health promotion interventions. *Ageing and Society*, 25(1), 41-67. <https://doi.org/10.1017/S0144686X04002594>

Comunidad Valenciana. (2023). Ley 3/2023, de 13 de abril, de viviendas colaborativas de la Comunitat Valenciana. *Boletín Oficial del Estado*, núm. 100, 27 de abril de 2023. Recuperado de <https://www.boe.es/buscar/pdf/2023/BOE-A-2023-10134-consolidado.pdf>

Conde, M. (2024, 12 de noviembre). The senior 'coliving' phenomenon is booming in Spain. *La Vanguardia*. Recuperado de <https://www.lavanguardia.com/vivo/longevity/20241112/10095898/fenomeno-coliving-senior-auge-residencias-te-aparcan-quiero-esclavizar-mis-hijos.html>

Crum, M., y Rayhorn, C. (2019). *Using Monte Carlo Simulation for Pro Forma Financial Statements*. *Journal of Accounting and Finance*, 19 (5), 29-39. <https://doi.org/10.33423/jaf.v19i5.2248>

CSIC (s.f.). Estadísticas sobre residencias: Residencias para personas mayores por provincia, 2015–2022 [Archivo Excel]. *Envejecimiento en red*. Recuperado el 28 de marzo del 2025 de

<http://envejecimiento.csic.es/estadisticas/indicadores/residencias/index.html>

Eurostat. (2023). Esperanza de vida al nacer por Comunidades Autónomas y en la Unión Europea, 2004-2023 [Archivo Excel]. *Instituto Nacional de Estadística*. Recuperado de https://www.ine.es/ss/Satellite?L=es_ES&c=INESeccion_C&cid=1259944484459&p=1254735110672&pagename=ProductosYServicios%2FPYSLayout¶m1=PYSDetalleFichaIndicador¶m3=1259937499084

Fundación Adecco. (s.f.). El envejecimiento alcanza un nuevo máximo histórico en España, del 137,3%: se contabilizan 137 personas mayores de 64 años por cada 100 menores de 16 [Nota de prensa]. Recuperado de <https://fundacionadecco.org/notas-de-prensa/el-envejecimiento-alcanza-un-nuevo-maximo-historico-en-espana-del-1373-se-contabilizan-137-personas-mayores-de-64-anos-por-cada-100-menores-de-16/>

Geriatricarea (mayo del 2024). Los precios medios de las residencias de mayores varían mucho entre las provincias españolas. Recuperado de <https://www.geriatricarea.com/2024/05/31/precios-de-las-residencias-de-mayores-por-provincias-de-espana-en-2024/>

Inforesidencias (5 de septiembre del 2023). El precio medio de una residencia de la tercera edad privada en España es de 1.990€ al mes en 2023. Recuperado de <https://www.inforesidencias.com/contenidos/noticias/nacional/el-precio-medio-de-una-residencia-de-la-tercera-edad-privada-en-espa-a-es-de-1990-al-mes-en-2023>

INE (s.f.-a). Esperanza de vida al nacimiento por provincia, según sexo [Archivo Excel]. Recuperado el 28 de marzo del 2025 de <https://ine.es/jaxiT3/Tabla.htm?t=1485>

INE (s.f.-b). Índice de envejecimiento por año [Archivo Excel]. Recuperado

el 16 de marzo de 2025, de <https://www.ine.es/jaxiT3/Tabla.htm?t=36667&L=0>

INE (s.f.-c). Índice de envejecimiento por provincia <https://ine.es/jaxiT3/Tabla.htm?t=1489>

INE (s.f.-d). Número de hogares unipersonales por provincias según sexo, edad y nacionalidad [Archivo Excel]. Recuperado el 28 de marzo de 2025 de <https://datos.gob.es/es/catalogo/ea0010587-numero-de-hogares-unipersonales-por-provincias-segun-sexo-edad-y-nacionalidad-identificador-api-t20-p274-serie-def-p03-10-03013-px1>

INE (s.f.-e). Número de hogares unipersonales por provincias según el tipo de hogar y el régimen de tenencia de la vivienda [Archivo Excel]. Recuperado el 28 de marzo del 2025 de <https://datos.gob.es/es/catalogo/ea0010587-numero-de-hogares-por-provincias-segun-el-tipo-de-hogar-y-el-regimen-de-tenencia-de-la-vivienda-identificador-api-t20-p274-serie-def-p03-10-03009-px1>

INE (s.f.-f). Principales series de población desde 1998: Población por comunidades, edad (grupos quinquenales), Españoles/Extranjeros, Sexo y Año, 1998-2022 [Archivo Excel]. Recuperado el 13 de marzo de 2025, de <https://www.ine.es/jaxi/Tabla.htm?L=0&file=02002.px&path=%2Ft20%2Fe245%2Fp08%2F>

INE. (s.f.-g). Proporción de población mayor de cierta edad por año [Archivo Excel]. Recuperado el 14 de marzo del 2025, de <https://www.ine.es/jaxiT3/Tabla.htm?t=36666&L=0>

INE (s.f.-h). Tasa de dependencia de la población mayor de 64 años, por comunidad autónoma [Archivo Excel]. Recuperado el 28 de marzo del 2025 de <https://ine.es/jaxiT3/Tabla.htm?t=1492&L=0>

Instituto Geográfico Nacional. (s.f.). Estructura demográfica. *Atlas Nacional de España*. Recuperado el 17 de marzo de 2025, de https://atlasnacional.ign.es/wane/Estructura_demogr%C3%A1fica

López Letón, S. (22 de noviembre del 2021). Spain sets its sights on Europe's retirees. *El País*. Recuperado de <https://elpais.com/economia/2021-11-22/spain-sets-its-sights-on-europes-retirees.html>

Lospitao, C. (8 de junio del 2022). España tiene que invertir 1.400 millones al año en 'senior living' para cumplir con la OMS. *Idealista News*. Recuperado de <https://www.idealista.com/news/inmobiliario/vivienda/2022/06/08/797122-espana-tiene-que-invertir-1-400-millones-al-ano-en-senior-living-para-cumplir-con-la>

Martínez, E. G. (26 de marzo del 2025). ¿Cuánto cuesta una casa prefabricada? Precios y modelos disponibles. *Idealista News*. Recuperado de <https://www.idealista.com/news/inmobiliario/vivienda/2018/11/21/769643-cuanto-cuesta-una-casa-prefabricada-precios-y-modelos>

Ministerio de Inclusión, Seguridad Social y Migraciones (27 de septiembre de 2024). La pensión media de jubilación asciende a 1.445,75 euros, un 5% más que hace un año [Archivo Excel]. Recuperado el 22 de marzo del 2025, de <https://www.inclusion.gob.es/w/la-pension-media-de-jubilacion-asciende-a-1.445-75-euros-un-5-mas-que-hace-un-ano>

Ministerio de Transportes y Movilidad Sostenible (s.f.). Estadística de precios de suelo urbano. Precio medio del metro cuadrado de suelo urbano por comunidades autónomas y provincias [Archivo Excel]. Recuperado el 22 de marzo del 2025 de <https://apps.fomento.gob.es/BoletinOnline2/?nivel=2&orden=36000000>

Organización Mundial de la Salud. (20 de octubre del 2023). Salud mental de los adultos mayores. Recuperado de <https://www.who.int/es/news-room/fact-sheets/detail/mental-health-of-older-adults>

Pareja, C. (22 de junio del 2022). DomusVi apuesta por el ‘senior living’: un 30% de sus nuevas residencias serán con este modelo. *Idealista News*. Recuperado de <https://www.idealista.com/news/inmobiliario/vivienda/2022/06/22/797434-domusvi-apuesta-por-el-senior-living-un-30-de-sus-nuevas-residencias-seran-con-este>

Puga, D. (2023). España, país de propietarios: el 92% de los hogares con un adulto mayor de 65 años tiene la casa pagada. *Libre Mercado*. Recuperado de https://www.libremercado.com/2023-09-30/la-vivienda-en-propiedad-en-espana-7050204/?utm_campaign=url_rewrite&utm_medium=Social&utm_source=Twitter

Silver Economy Group. (s.f.). Nuevas alternativas de vivienda para mayores. Recuperado el 10 de abril de 2025, de <https://silvereconomygroup.com/nuevas-alternativas-de-vivienda-para-mayores>

Sosa Troya, M. (24 de junio del 2024). España en 2039: un tercio de los hogares será de una persona sola y se triplica el número de centenarios. *El País*. Recuperado de <https://elpais.com/sociedad/2024-06-24/espana-en-2039-un-tercio-de-los-hogares-seran-de-una-persona-sola-y-se-triplica-el-numero-de-centenarios.html>

Universidad Pontificia de Comillas (8 de julio del 2021). ¿Qué es la silver economy y qué oportunidades ofrece? Recuperado de <https://www.comillas.edu/noticias/que-es-la-silver-economy-y-que-oportunidades-ofrece/>